

**SVEUČILIŠTE U RIJECI
TEHNIČKI FAKULTET**

**HIJERARHIJSKO MODELIRANJE KAO OSNOVA
METODOLOGIJE PROJEKTIRANJA OPTIMALNOG
RASPOREDA PROIZVODNIH POVRŠINA
BRODOGRADILIŠTA**

Doktorska disertacija

Mentor: Red. prof. dr. sc. Nikša Fafandjel, dipl. ing.

Rijeka, 2009.

SAŽETAK

U radu je predložena metodologija za projektiranje optimalnog rasporeda proizvodnih površina brodogradilišta u preliminarnoj fazi. U prvom su dijelu rada, kroz dostupne izvore, istražene metode, tehnike i alati koji se općenito primjenjuju kod problema projektiranja rasporeda površina. Nadalje, na temelju istraženog, izvršen je odabir posebnih metoda, tehnika i alata od kojih su određeni posebno prilagođeni potrebama ovdje predložene metodologije, a koja se temelji na provođenju točno definirane procedure u četiri faze. U prvoj fazi utvrđeni su odnosi bliskosti odabranih proizvodnih površina sa stajališta tehnološkičnosti brodograđevnog procesa, na temelju provedenog anketiranja relevantnih eksperata. Zatim se, u drugoj fazi predlaže generiranje te procjena svih mogućih varijanti rasporeda odabranih proizvodnih površina u okvire brodogradilišta. Za tu svrhu primijenjena je metoda sistematskog planiranja rasporeda površina na temelju prethodno utvrđenih odnosa bliskosti. Nadalje, nakon utvrđenog reprezentativnog broja najizglednijih varijanti, u trećoj fazi se među tim varijantama hijerarhijskim modeliranjem, za koje se koristi metoda analitičkog hijerarhijskog procesa, vrši izbor one koja optimalno udovoljava svim postavljenim kriterijima. U zadnjoj, četvrtoj fazi vrši se analiza osjetljivosti kako bi se ispitala stabilnost odabranog rješenja rasporeda proizvodnih površina. Zatim se na projektnom rješenju osniva plan pripadajućih proizvodnih tokova. U završnom dijelu rada provjerena je primjena predložene metodologije kod projektiranja rasporeda proizvodnih površina jednog postojećeg brodogradilišta.

ABSTRACT

A novel methodology for creating a preliminary optimal layout design of shipyard production areas is proposed in this dissertation. The first part includes research of methods, techniques and tools which are presently used to solve the problem of arrangement design. Furthermore, based upon research, specific methods, techniques and tools were chosen, modified and adapted to the needs of the proposed methodology, which is based on the implementation of a specifically defined procedure in four phases. The first phase established the closeness relationships of the chosen production areas from the shipbuilding process technological point of view, based upon a survey of relevant experts. Thereupon, the second phase proposed the generation and valuation of all possible production layout variants within the shipyard. The method of systematic layout planning based on previously established closeness relationships was used. Furthermore, after establishing a representative number of most competitive variants, the third phase considers hierarchical modeling, by using the analytical hierarchy process, to choose the variant which most optimally satisfies all criteria. In the fourth and final phase, a sensitivity analysis is made in order to check the stability of the chosen layout of production areas. Then a plan of the corresponding production flow is created, which is based on the design solution. In the last part of the dissertation, the proposed methodology was applied to the production layout design of an existing shipyard.

PREDGOVOR

Doktorsku disertaciju „Hijerarhijsko modeliranje kao osnova metodologije projektiranja optimalnog rasporeda proizvodnih površina brodogradilišta“ izradio sam pod mentorstvom red. prof. dr. sc. Nikše Fafandjela. Disertacija je izrađena u okviru znanstvenog projekta Ministarstva znanosti, obrazovanja i športa Republike Hrvatske pod nazivom „Tehnološko unapređenje metodologije gradnje trupa broda“ čiji je voditelj također red. prof. dr. sc. Nikša Fafandjel. Kao član tima, na spomenutom projektu, sudjelovao sam na većem broju znanstveno istraživačkih projekata za privredu gdje sam, uz redovni znanstveni i stručni rad na poslijediplomskom studiju stekao dodatna posebna znanja i vještine te informacije bez kojih ne bi bilo moguće izraditi ovaj rad.

Ovim putem želim se zahvaliti svima koji su pomogli u realizaciji ovog rada. Posebno se zahvaljujem svom mentoru red. prof. dr. sc. Nikši Fafandjelu što mi je omogućio da budem dio *tima*. Nadalje veliko hvala što je uvijek bio na raspolaganju s brojnim cijenjenim savjetima i pomoći tijekom izrade rada.

Zatim posebnu zahvalu upućujem članovima povjerenstava red. prof. dr. sc. Senki Maćešić i red. prof. dr. sc. Roku Markovini.

Zahvaljujem se i prof. dr. sc. Charlesu E. Donagheyju sa Cullen College of Engineering Sveučilišta u Houstonu, autoru specijaliziranog *SLP* programa *BlockPlan*, koji mi je istoga učinio dostupnim za potrebe ovoga rada.

Također se zahvaljujem kolegama s Katedre za tehnologiju i organizaciju brodogradnje Tehničkog fakulteta Sveučilišta u Rijeci, kolegama s Fakulteta elektrotehnike, strojarstva i brodogradnje Sveučilišta u Splitu, kolegama s Fakulteta strojarstva i brodogradnje Sveučilišta u Zagrebu, te kolegama iz brodogradilišta „Kraljevica“, „Brodosplit“, „Uljanik“, „3. maj“ i „Brodotrogir“ za pomoć prilikom prikupljanja podataka.

Ovaj rad posvećujem cijeloj svojoj obitelji koja je bila velika podrška, prepuna razumijevanja u mom znanstvenom i stručnom radu, a posebno mojoj predivnoj supruzi Marini i mojoj prekrasnoj djeci, Valu, Mistralu i Iris.

Autor

SADRŽAJ

1	UVOD.....	1
1.1	Projektiranje rasporeda površina.....	1
1.2	Postavljanje problema	2
1.3	Polazište istraživanja.....	3
1.4	Očekivani rezultati i njihova primjena.....	4
1.5	Sažetak	5
2	DOSADAŠNJA ISTRAŽIVANJA I SPOZNAJE U PROJEKTIRANJU RASPOREDA POVRŠINA.....	7
2.1	Uvod.....	7
2.2	Kategorije projektiranja rasporeda površina	7
2.2.1	Projektiranje rasporeda površina proizvodnih sustava i građevina.....	8
2.2.2	Projektiranje rasporeda tokova električnih sklopova	8
2.2.3	Projektiranje rasporeda površina temeljeno na korisničkom sučelju.....	9
2.2.4	Projektiranje rasporeda površina temeljeno na optimalnom slaganju	9
2.3	Matematičke formulacije	10
2.3.1	Kvadratni problem pridruživanja	10
2.3.2	Kvadratni problem prekrivanja skupova	10
2.3.3	Dvodimenzijski problem pravokutnog slaganja	11
2.3.4	Nedostaci postojećih formulacija.....	11
2.4	Tehnike projektiranja	12
2.4.1	Konvencionalni pristupi.....	12
2.4.2	Heuristički pristupi.....	13
2.5	Neodređenosti kod projektiranja.....	16
2.5.1	Izvorišta neodređenosti	16
2.5.2	Klasifikacija neodređenosti.....	17
2.5.3	Konvencionalni pristupi upravljanju neodređenostima	18
2.5.4	Računalni pristupi upravljanju neodređenostima.....	21
2.5.5	Usporedba pristupa za upravljanje neodređenostima.....	22
2.6	Automatizirano projektiranje	24
2.6.1	Postojeći sistemi.....	24
2.6.2	Ograničenja postojećih sistema.....	25
2.7	Perspektivne računalne tehnike i alati.....	26
2.7.1	Genetički algoritmi	26
2.7.2	Umjetne neuronske mreže.....	27
2.7.3	Metoda učenja pojačavanjem.....	28
2.7.4	Sustavi temeljeni na znanju	28
2.8	Sažetak	28
3	CILJ ISTRAŽIVANJA	31
3.1	Područje istraživanja	31
3.2	Postavljanje cilja istraživanja.....	33
4	PRIJEDLOG METODOLOGIJE ZA PROJEKTIRANJE OPTIMALNOG RASPOREDA PROIZVODNIH POVRŠINA BRODOGRADILIŠTA.....	35
4.1	FAZA 1 – Utvrđivanje pokazatelja odnosa bliskosti odabranih proizvodnih površina brodogradilišta metodom anketiranja.....	37
4.1.1	Uvod.....	37
4.1.2	Odabir relevantnih proizvodnih površina brodogradilišta	40
4.1.3	Utvrđivanje pokazatelja odnosa bliskosti i pripadajućih težinskih faktora.....	43
4.1.4	Prijedlog za daljnje unapređenje faze 1	45

4.2	FAZA 2 – Generiranje svih mogućih rješenja rasporeda razmatranih proizvodnih površina korištenjem SLP metode te odabir najizglednijih temeljem utvrđenih odnosa bliskosti	46
4.2.1	Uvod.....	46
4.2.2	Prikaz sistematskog planiranja rasporeda površina	47
4.2.3	Računalski program za sistematsko planiranje rasporeda površina.....	51
4.3	FAZA 3 – Hijerarhijsko modeliranje AHP metodom za projektiranje optimalnog rasporeda razmatranih proizvodnih površina brodogradilišta	55
4.3.1	Uvod.....	55
4.3.2	Utvrđivanje potencijalnih parametara za hijerarhijsko rangiranje.....	55
4.3.3	Metodološki temelji analitičkog hijerarhijskog procesa	58
4.3.4	Matematički temelji analitičkog hijerarhijskog procesa	59
4.3.5	Posebno prilagođeni <i>AHP</i> alat za hijerarhijsko modeliranje optimalnog rasporeda proizvodnih površina brodogradilišta.....	66
4.4	FAZA 4 – Utvrđivanje stabilnosti projektiranog rasporeda proizvodnih površina brodogradilišta primjenom analize osjetljivosti.....	72
4.4.1	Uvod.....	72
4.4.2	Provođenje empirijske analize osjetljivosti	73
4.4.3	Dinamička analiza osjetljivosti	74
4.4.4	Analiza izvedbene osjetljivosti	76
4.4.5	Analiza dijagramom stupnja osjetljivosti	77
4.4.6	Analiza dijagramom sučeljavanja	78
4.5	Sažetak	79
5	PROVJERA PREDLOŽENE METODOLOGIJE NA PRIMJERU POSTOJEĆEG BRODOGRADILIŠTA.....	81
5.1	FAZA 1 – Analiza ulaznih podataka i implementacija utvrđenih odnosa bliskosti razmatranih proizvodnih površina	81
5.1.1	Osnovne značajke rasporeda površina postojećeg brodogradilišta.....	81
5.1.2	Definiranje proizvodnog programa.....	84
5.2	FAZA 2 – Generiranje mogućih rješenja rasporeda proizvodnih površina postojećeg brodogradilišta korištenjem SLP metode te odabir najizglednijih temeljem utvrđenih odnosa bliskosti	90
5.3	FAZA 3 – Projektiranje optimalnog rasporeda proizvodnih površina postojećeg brodogradilišta hijerarhijskim modeliranjem	115
5.4	FAZA 4 – Utvrđivanje stabilnosti projektirane varijante rasporeda proizvodnih površina postojećeg brodogradilišta analizom osjetljivosti	132
5.4.1	Dinamička analiza osjetljivosti	132
5.4.2	Analiza izvedbene osjetljivosti	132
5.4.3	Analiza dijagramom stupnja osjetljivosti	134
5.4.4	Analiza dijagramom sučeljavanja	138
5.5	Odabrano optimalno projektno rješenje kao podloga za osnivanje proizvodnih tokova	145
6.	ZAKLJUČAK	151
	Popis literature.....	155
	Popis oznaka i kratica.....	163
	Popis slika	165
	Popis tablica.....	169
	Popis priloga.....	171
	Prilog 1.	173
	Prilog 2.	178
	Prilog 3.	186

1 UVOD

Potreba za kontinuiranim tehnološkim unapređivanjem i širenjem složenih proizvodnih sustava kao što je brodogradilište dovodi do potrebe donošenja vrlo kompleksnih i odgovornih odluka, koje moraju biti adekvatno argumentirane i prije svega ispravne, kako bi ona ostala konkurentna na svjetskom brodograđevnom tržištu. Veliki broj kontradiktornih zahtjeva te posebnih ograničenja mora biti analiziran i ponderiran kako bi se uopće moglo približiti nekim prihvatljivim rješenjima, dok su za odabir optimalnih rješenja potrebne dodatne analize i proračuni korištenjem niza znanstvenih metoda, tehnika i alata.

Međutim, česta nemogućnost prostornog širenja takvih kompleksnih sustava zbog raznih objektivnih ograničenja, kao što su omeđenost morem, drugom industrijom, urbanom sredinom, zatim zakonskom regulativom te drugim ograničenjima primjerice onim koja postavlja europska zajednica, sužava potencijalne mogućnosti tehnološke modernizacije. Unapređenje postojećih proizvodnih procesa nužno dovodi do potrebe reorganizacije rasporeda proizvodnih površina samo u postojećim prostornim okvirima.

Čest je slučaj da su zbog nedostatka pristupačnih metodologija koje obuhvaćaju posebne znanstvene metode, tehnike i alate, kao i nužnih podataka za donošenje odluka kod ovakvog problema, rukovodstva brodogradilišta primorana svoje odluke donositi temeljem iskustva i/ili putem uspoređivanja s drugima i sl. Ovakav pristup najčešće ne dovodi do izbora optimalnih rješenja, što predstavlja poticaj za temeljitu analizu te razmišljanje o novoj metodologiji za projektiranje rasporeda proizvodnih površina brodogradilišta. Takva metodologija trebala bi obuhvatiti znanstvene metode, tehnike i alate kako bi brzo i efikasno dovođila do takvih rješenja rasporeda proizvodnih površina koja bi optimalno zadovoljavala postavljena ograničenja, te pritom bila primjenjiva i razumljiva prioritetno rukovodstvu brodogradilišta.

1.1 Projektiranje rasporeda površina

Općenito proces projektiranja rasporeda površina usmjeren je ka traženju optimalnih rješenja u određivanju prostora za različite aktivnosti s pripadajućim komponentama. Spomenuti proces predstavlja određivanje rasporeda površina unutar određenog prostora,

kako bi optimalno zadovoljio zadane postavke i ograničenja. Zadane postavke uključuju visok stupanj neodređenosti [1], [2]. Intenzivna znanstvena djelatnost, a istovremeno nedostatak primjerenih modela koji se bave složenom dinamikom odlučivanja, zatim nedostatak pravovremenih stručnih informacija i gospodarskih trendova istaknuo je potrebu predlaganja izvjesnih znanstveno-utemeljenih podrški u odlučivanju kroz specijalizirane metodologije projektiranja. Ovakve podrške u odlučivanju te specijalizirane metodologije uspješno su razvijane u različitim granama poput tehnike, medicine, trgovine, itd. [3], [4]. Međutim, iste metodologije u vrlo značajnom području poput projektiranja rasporeda površina nisu doživjele adekvatan razvoj [5].

Očito je da se proces projektiranja rasporeda površina temelji na kreativnosti projektanta kao i na korištenju interakcije te kompromisa rezultata različitih konkurentnih i kontradiktornih disciplina [6]. Poznato je da većina kompjuteriziranih tehnika projektiranja rasporeda površina ograničava i/ili ignorira kreativnost i talent projektanta koji razumije kompleksan odnos proizvodnih tokova i prostora [7]. Ovi navodi aktualni su i danas [8].

Za istu svrhu koristi se i pristup temeljen na ekspertizi donosioca odluka, kao i tehnikama prikladnim za modeliranje neodređenih problema. Takav *Ekspertni pristup* (engl. *Expert System*) moguće je primijeniti i za projektiranje rasporeda površina u brodogradnji.

Jedan od vrlo učinkovitih i široko primjenjivih alata za povezivanje subjektivnih i neodređenih postavki sa *Ekspertnim pristupom* jest *Neizrazita Logika* (engl. *Fuzzy Logic*), [9]. Slično tomu, alati poput *Umjetnih neuronskih mreža* (engl. *Artificial Neural Networks*) omogućavaju automatsko lociranje, vrednovanje i ažuriranje nekih od implicitnih i eksplicitnih postavki [10]. Naime, vjeruje se da automatizirani procesi adaptacije rasporeda površina temeljeni na *Ekspertnom pristupu* uz korištenje skupnih prednosti odabranih metoda, tehnika i alata nude dobre smjernice za istraživanje [11].

1.2 Postavljanje problema

Kako bi brodogradilišta opstala i bila konkurentna na svjetskom tržištu ona kontinuirano moraju ulagati u svoj proizvodni proces s ciljem optimiranja kapaciteta i proizvodnje radi povećanja proizvodnosti i profita. Budući su gotovo sva velika hrvatska brodogradilišta osnovana prije stotinjak i više godina, ona su u tu svrhu bila izložena

brojnim izmjenama kako proizvodnog procesa tako i same konfiguracije. Njihov je izvorni tlocrt sadržavao uglavnom navoze i nekolicinu pripadajućih radionica, kao rezultat tadašnje razine tehnologije i korištenih materijala. Razvojem brodogradnje postepeno se mijenjao proces gradnje broda, mijenjali su se materijali za gradnju broda, tehnologija gradnje, izbor opreme, rasla je proizvodnost, a sve je to zahtijevalo i drugačiju konfiguraciju brodogradilišta s novim, dodatnim proizvodnim radionicama i površinama, te suvremenom radnom opremom. Kako su brodogradilišta već imala određeni broj radionica i površina, rješenja su se redovito pronalazila u širenju oko već postojećih sadržaja. Takva rješenja su u određenim okolnostima bila zadovoljavajuća, međutim ne i optimalna sa stajališta brodograđevnog proizvodnog procesa. U tom smislu, a naročito iz činjenice da su daljnja prostorna širenja brodogradilišta gotovo nemoguća, javlja se potreba za primjenom znanstvenih metoda u praćenju i otkrivanju mogućnosti poboljšanja proizvodnog procesa s stajališta reorganizacije rasporeda postojećih površina u svrhu optimizacije proizvodnih tokova brodograđevnog procesa. Primjer tome je, prije svega, primjena operacijskih istraživanja, među kojima ponajviše primjena odgovarajućih matematičkih metoda (statističkih metoda, metoda odlučivanja, analize osjetljivosti, metode vrednovanja kriterija, matrice odlučivanja, itd.). Međutim, većina stvarnih procesa je vrlo složena te ih je teško opisati analitički.

Radi navedenih povijesnih razloga, postojeća brodogradilišta imaju bitno drugačiji raspored proizvodnih površina od onog kakav bi bio kad bi se ona projektirala sa današnjom razinom znanstvenih i stručnih spoznaja. Takav nesrazmjer upravo predstavlja i problem, jer su proizvodni tokovi u takvim brodogradilištima danas nedovoljno efikasni te ih je potrebno optimizirati, ali vodeći pritom računa o svim postojećim te postavljenim ograničenjima.

1.3 Polazište istraživanja

Dosadašnjim radom i istraživanjem na raznim projektima za gospodarstvo izučavano je više metoda primijenjenih operacijskih istraživanja, upoznalo se s projektiranjem proizvodnih procesa i tokova u brodogradilištima, savladalo se više specijaliziranih računalskih alata, a pored teorijskih osnova pobliže se upoznalo i s njihovom praktičnom primjenom u pogonima brodogradilišta «3.MAJ», «Uljanik», «Brodosplit», «Brodotrogir» i „Brodogradilišta Kraljevica“.

Na temelju dobivenih spoznaja utvrđeno je da se u brodogradnji za rješavanje problema projektiranja rasporeda proizvodnih površina ne koriste dovoljno suvremene metode primijenjenih operacijskih istraživanja, kako bi se prije svega utvrdilo stanje, odnosno razina učinkovitosti postojećeg rasporeda površina, a zatim i odredila optimalna rješenja radi poboljšavanja istih kroz tehnološku obnovu, kao i radi projektiranja novih brodogradilišta u budućnosti.

Stoga se uočila potreba za iznalaženjem prikladne, a napose primjenjive metodologije za projektiranje rasporeda proizvodnih površina brodogradilišta. Kroz istraživanje utvrdilo se da primjena analitičkog hijerarhijskog procesa (engl. *Analytic Hierarchy Process*, AHP) [12], kao osnovnog alata, uz odgovarajuću primjenu ostalih odabranih alata operacijskih istraživanja i to primarno onog za sistematsko planiranje rasporeda površina (engl. *Systematic Layout Planning*, SLP) [13], zatim vrednovanje kriterija i analizu osjetljivosti, može rezultirati kvalitetnim iskorakom te doprinosom u rješavanju navedenog problema.

1.4 Očekivani rezultati i njihova primjena

Primjenom predložene metodologije očekuje se unapređenje postupka projektiranja rasporeda proizvodnih površina brodogradilišta koja će rezultirati ponuđenim rješenjima na sljedećim područjima:

- utvrđivanje najpovoljnijeg razmještaja proizvodnih površina za tehnološke procese proizvodnog programa brodogradilišta,
- optimizacija proizvodnih tokova brodograđevnog proizvodnog procesa,
- povećanje pouzdanosti prilikom donošenja relevantnih odluka za projektiranje restrukturiranja postojećih odnosno strukturiranja novih brodogradilišta.

U konačnici, primjena predložene metodologije rezultirat će projektiranjem optimalnog rasporeda proizvodnih površina brodogradilišta. Takvim rasporedom postići će se maksimalna iskorištenost resursa uz poštivanje tehnoloških ograničenja brodogradilišta. Stoga se očekuje doprinos samom pristupu projektiranja rasporeda proizvodnih površina brodogradilišta kod tehnoloških obnova brodogradilišta, te kod osnivanja novih.

Osnivanjem posebne metodologije projektiranja optimalnog rasporeda proizvodnih površina brodogradilišta temeljem hijerarhijskog modeliranja, u ovom se radu želi pridonijeti razvoju i sustavnoj primjeni određenih znanstveno utemeljenih metoda i alata.

Temeljem predložene metodologije, te analizom primjenjivosti iste u specifičnim slučajevima želi se dati doprinos učinkovitom odabiru i primjeni hijerarhijskog modeliranja i drugih alata operacijskih istraživanja, te istaknuti njihovu svrhovitost i primjenjivost.

1.5 Sažetak

U ovom poglavlju prikazan je problem nazočan u procesu projektiranja optimalnog rasporeda proizvodnih površina brodogradilišta te je predložena metodologija za njegovo rješavanje. U tu svrhu predstavljena je osnovna ideja osnivanja i razvoja metodologije za odlučivanje i podršku u procesu projektiranja rasporeda površina temeljena na ekspertnom pristupu uz korištenje skupnih prednosti odabranih metoda, tehnika i alata. Dakle, primjenom spomenutih osnovnih metoda, tehnika i alata poput analitičkog hijerarhijskog procesa, sistematskog planiranja rasporeda površina te uz određene metode operacijskih istraživanja kao što je metoda anketiranja i analiza osjetljivosti, nudi se nova metodologija za specifičnu primjenu u industrijskoj grani kao što je brodogradnja, koja će problem projektiranja rasporeda proizvodnih površina i pripadajućih proizvodnih tokova realizirati učinkovitije od dosadašnjih pristupa. Od predložene metodologije se očekuje da osigura temeljne smjernice ekspertima/projektantima u projektiranju brodogradilišta kako bi omogućila njihovu uspješnost. U sljedećem poglavlju dan je pregled relevantne literature dosadašnjih spoznaja u projektiranju rasporeda površina.

2 DOSADAŠNJA ISTRAŽIVANJA I SPOZNAJE U PROJEKTIRANJU RASPOREDA POVRŠINA

2.1 Uvod

Proces projektiranja rasporeda površina nužno ujedinjuje širok spektar različitih metoda, tehnika i alata, kao što su teorije odlučivanja, ekspertni sistemi, računalskii ostali alati, ali i ljudske faktore i saznanja. Stoga, prije odabira konkretne metodologije predložene ovim radom, izvršen je temeljit pregled svih navedenih disciplina te dosadašnjih istraživanja kroz dostupne izvore. Pregled navedenih istraživanja sa stajališta projektiranja rasporeda površina te obuhvaćene literature obrađen je u nastavku.

2.2 Kategorije projektiranja rasporeda površina

Projektiranje rasporeda površina (*engl. Layout Design*), kako je već spomenuto, predstavlja određivanje prostornog rasporeda odabranih površina unutar određenog prostora, uz optimalno zadovoljenje zadanih postavki i ograničenja. To je složen proces koji zahtjeva primjenu adekvatnih metoda, tehnika i alata [6], [14]. Konkretnije, to je neodređen i loše strukturiran problem gdje dinamika uključenih radova, nedostupnost podataka te kontradiktornost zahtjeva, često sprječavaju u izboru optimalnog rješenja, [15]. Stoga, zbog kompleksnosti problema te raznih ograničenja, projektanti pribjegavaju primjeni pojednostavljenih procedura, [16].

Jasno je da se, s obzirom na širinu primjenjivosti procesa projektiranja rasporeda površina, nailazi na vrlo različitu literaturu namijenjenu određenom području primjene [6], [15], [17], [18], [19]. Projektiranje rasporeda površina se na razne načine primjenjivalo u optimizaciji položaja (*engl. topology optimization*) [20], pozicioniranju blokova (*engl. block placement*) [21], pozicioniranju makro-čelija (*engl. macro cell placement*) [22], optimizaciji rasporeda površina (*engl. layout optimization*) [23], određivanju rasporeda površina unutar objekata (*engl. facilities layout*) [24], zatim razmještanju postrojenja ili strojeva (*engl. plant layout or machine layout*) [25], unapređenju slaganja (*engl. bin-packing*) [26] i sortiranju (*engl. partioning*) [27], itd.

Projektiranje rasporeda površina može se podijeliti u četiri osnovne kategorije prema primjeni, a to su projektiranje rasporeda:

- površina proizvodnih sustava i građevina (*engl. Facilities Layout Design*),
- elektroničkih sklopova (*engl. Circuit Layout Design*),
- površina temeljem korisničkog sučelja (*engl. User Interface Layout Design*),
- površina optimalnim slaganjem (*engl. Bin-Packing Layout Design*).

Slijedi kratak opis značajki pojedinih osnovnih kategorija projektiranja.

2.2.1 Projektiranje rasporeda površina proizvodnih sustava i građevina

Pri projektiranju i definiranju rasporeda površina unutar objekata, razne aktivnosti i komponente predstavljaju se kao određene površine u zadanom prostoru. Raspored površina unutar objekta zasniva se na fizikalnom odnosu između pojedinih aktivnosti i njihovih ciljeva [28]. Ono također može bitno utjecati na očuvanje okoliša te sigurnost. Prema tome, odluke pri dodjeljivanju površina unutar određenog prostora temelje se na raznim komunikacijskim, političkim, socijalnim, ekološkim i sigurnosnim zahtjevima [29]. Jasno je da adekvatno projektiran raspored površina unutar nekog objekta unapređuje iskoristivost, efikasnost, produktivnost te profit neke organizacije [30].

2.2.2 Projektiranje rasporeda tokova električnih sklopova

Važan korak u projektiranju rasporeda površina predstavlja smještaj makro-ćelija temeljen na nizu subjektivnih i kontradiktornih postavki i zahtjeva. Makro-ćelije predstavljaju komponente unutar komunikacijskih tokova smještene u određenom prostoru i povezane u funkcionalne subjekte preko spojnih terminala na njihovim krajevima. Spojni terminali se umrežuju s ostalim komponentama kako bi se osigurala komunikacija. Izbor razmještaja komponenti uvjetuje komunikacijske tokove umreženja. Stoga se nastoji izvršiti takav izbor razmještaja komponenti koji će osigurati njihov cjelovit smještaj i funkcionalnost sa pripadajućim umreženjem na što manjoj pravokutnoj površini. Iskoristivost određenog razmještaja izražava se kao omjer iskorištene površine i ukupne površine, [11]. Jasno je da je ova kategorija projektiranja rasporeda površina vrlo značajna u elektrotehnici kod projektiranja čipova [31], ali se zbog kontinuiranog razvoja ovog

znanstvenog polja javlja potreba za kontinuiranim unapređenjem tehnika optimizacije i ovakvih površina [32].

2.2.3 Projektiranje rasporeda površina temeljeno na korisničkom sučelju

Osnovna značajka ove kategorije je da korisničko sučelje određuje strukturu, svrhu, operacije i značajke promatranog procesa [33]. Početna pretpostavka jest da dobro sučelje s pripadajućom površinom ima značajnu ulogu u daljnjoj uspješnosti cijelog procesa [34]. Korisnici raznih sučelja između čovjeka i stroja dolaze iz različitih područja. Stoga, postupci korisnika evoluiraju sa promjenama u kontekstu primjene, ali i sa unapređenjem samog korisnika [35]. Takva evoluirajuća osobina korisnika znači potrebu za prilagodljivim sučeljem koje udovoljava njegovim potrebama i očekivanjima u strukturi i funkcionalnosti konačnog rješenja [18].

Prilagodljivo korisničko sučelje ima dugu povijest ucrtanu kroz nastanak tehnologija poput umjetne inteligencije, računalske tehnologije, grafičkog korisničkog sučelja, „pametnih“ korisničkih sučelja, *JAVA*-e, interneta, te komunikacijskih sustava [36]. Konkretnije, dolazak i napredak web-a i komunikacijskih sustava učinio je svojstvo prilagodljivosti vrlo važnom karakteristikom za uspješnost i prihvatljivost ovakvih usluga [33]. Međutim, ovakve aplikacije predstavljaju vrlo zahtjevnu kategoriju sa stajališta projektiranja rasporeda površina zbog velike različitosti populacije kojima je ona namijenjena [37]. Ipak, pokazalo se da su nastojanja za korisničkim modeliranjem (*engl. user-modeling*) jasna široj populaciji te mogu pomoći u prilagodbi sučelja [38]. Stoga, automatizacijski alati mogu imati važnu ulogu u ovoj kategoriji [39]. Tretirana kategorija šire je obrađena u raznim dostupnim literaturama [11], [33], [37].

2.2.4 Projektiranje rasporeda površina temeljeno na optimalnom slaganju

Kod problema optimalnog slaganja nastoji se što je moguće veći broj elemenata smjestiti u što manji određeni prostor [40]. Dakle, osnovni cilj je postići maksimalni stupanj iskoristivosti prostora [41]. Postoji nekoliko varijanti spomenutog problema optimalnog slaganja, pa se ono može temeljiti na dimenzijama i obliku elemenata u jednoj ili u svim osima, odnosno slaganju: pravokutnih, okruglih, čvrstih ili elastičnih, nepravilnih te ostalih elemenata. Nadalje, postoji više načina, tj. ograničenja na koje određeni problemi

moгу biti riješeni. Na primjer uz minimalnu zauzetost volumena, minimalnu masu, maksimalnu iskoristivost, maksimalnu učinkovitost, itd. [42], [43], [44].

2.3 Matematičke formulacije

Niz formulacija vezanih za problem projektiranja rasporeda površina predložen je u literaturi [44]. Najpoznatije formulacije koje se koriste kod projektiranja rasporeda površina su: Kvadratni problem pridruživanja (engl. *Quadratic Assignment Problem, QAP*), Kvadratni problem prekrivanja skupova (engl. *Quadratic Set-Covering, QSC*) [45] i Dvodimenzijski problem pravokutnog slaganja (engl. *Two-Dimensional Bin-Packing Problem, 2D-BPP*) [11]. U nastavku je dan kratak opis osnovnih značajki navedenih formulacija.

2.3.1 Kvadratni problem pridruživanja

Formulacije kvadratnog problema pridruživanja, *QAP*, kod projektiranja rasporeda površina koriste se međusobnim odnosima položaja dodirnih modula jednake površine. *QAP* je jedan od fundamentalnih problema operacijskih istraživanja u matematici vezan za kombinatorikalnu optimizaciju u pozicioniranju modula u određenom prostoru.

Međutim, *QAP* metoda polazi od pretpostavke da su svi moduli jednaki po svojim dimenzijama i obliku, kao i da su moguće lokacije za smještaj modula fiksne i unaprijed poznate. Iako postoji mogućnost, ako moduli nisu jednaki, da se oni rastave u pod-module i svi postanu jednaki, polazna pretpostavka bitno ograničava primjenu ove metode. Dodatna ograničenja proizlaze iz početnih zahtjeva vezanih za objektivnost, točnost te metriku. Naime, početni međusobni odnosi pojedinih modula pretpostavljaju se konstantnim, a ovakva pojednostavljenja i pretpostavke u većini slučajeva projektiranja rasporeda površina nisu prihvatljiva, [11].

2.3.2 Kvadratni problem prekrivanja skupova

Problem projektiranja rasporeda površina može se formulirati i pomoću kvadratnog problema prekrivanja skupova, *QSC*. Osnovni ulazni parametri obuhvaćeni u ovoj metodi odnose se na dimenzije svakog pojedinog modula, koordinate te namjenu svakog modula.

Stoga postoji mogućnost da korisnik, projektant, predloži lokaciju pojedinog modula kako bi se izbjegla mogućnost formiranja nekih nepovoljnih scenarija. Nadalje omogućuje da intuicija i stručnost korisnika dođu do izražaja pri usmjeravanju rada same metode unutar računala. Dakle od korisnika se traži niz ulaznih parametara za svaki pojedini razmatrani modul [8].

2.3.3 Dvodimenzijski problem pravokutnog slaganja

Projektiranje rasporeda površina može se prikazati i kao problem dvodimenzijskog pravokutnog slaganja, *2D-BPP*). Prednosti ove metode su u zadržavanju cjelovitosti i oblika modula, a optimizacijske dorade su minimalne u odnosu na druge prevladavajuće metode za projektiranje rasporeda površina. Nadalje, omogućuje genetički pristup mnogim problemima projektiranja rasporeda površina [17]. Osnovni prikazi ove metode teže ka optimalnom slaganju kako bi se što više modula smjestilo u određen prostor, [11].

2.3.4 Nedostaci postojećih formulacija

Postojeće matematičke formulacije za projektiranje rasporeda površina sadrže značajna ograničenja koja ih čine nekompatibilnima sa većinom realnih problema. Na primjer, *QAP* ne dozvoljava prilagođavanje oblika modula u rezultirajućem rasporedu, a *QSC* zahtijeva velik broj ulaznih podataka za svaki razmatrani modul [46]. Postojeće matematičke formulacije ne daju dovoljan doprinos pri njihovoj praktičnoj primjeni na realnim problemima i zbog ograničenja njihovih pripadajućih matematičkih programa. Temeljne karakteristike projektiranja rasporeda površina, kao što su loša strukturiranost i neodređenost problema dodatno čine ovakve matematičke formulacije neadekvatnima [47].

Ovakvi matematički programi oslanjaju se na iskrivljenim podacima raznih parametara za koje se pretpostavlja da su točno izmjereni te da se odnose na specifičan dio problema [48]. Međutim, u praksi ovakvi podaci mogu biti uporabljivi samo za određene nestvarne, pojednostavljene scenarije. Zbog toga su matematičke formulacije od male koristi kada se projektira relativno veći problem s uključenim razmatranjem svih pripadajućih karakteristika poput neodređenosti. Stoga se za rješavanje takvih problema, veća pozornost pridodaje brzim i efikasnim heurističkim metodama koje daju korisnije rezultate [17].

2.4 Tehnike projektiranja

Objavljen je veći broj radova koji predlažu razne heurističke i analitičke tehnike za rješavanje problema projektiranja rasporeda površina. Heurističke tehnike se najčešće temelje na *QAP* formulacijama [49]. Dvodimenzionalna ravnina se opisuje mrežnom strukturom koja rezultira dugotrajnim i skupim proračunom [50]. Neke tehnike za rješavanje uključuju algoritme stabla pretraživanja (engl. *tree search*) [51], binarno cjelobrojno programiranje (engl. *binary mixed integer-programming*) [52], te dekompoziciju mreže (engl. *network decomposition*) [53]. U nastavku je dan kratak osvrt na različite metodologije za rješavanje problema projektiranja rasporeda površina.

2.4.1 Konvencionalni pristupi

Kompleksni konvencionalni pristupi optimizacije pri tretiranju zahtjevnog i subjektivnog problema kao što je projektiranje rasporeda površina teško mogu dovesti do izglednih rješenja u nekom kratkom roku, stoga se ona danas rijetko primjenjuju. Međutim, u literaturi su ovakvi pristupi vrlo dostupni stoga će se dati samo njihov kratki opis.

2.4.1.1 Grafički algoritmi

Grafički algoritmi (engl. *Graph Algorithms*) za projektiranje rasporeda površina temeljeno uključuju tri osnovna koraka. Prvi je razvijanje tzv. granične krivulje (engl. *adjacency graph*) uz pomoć među-modularne interakcije susjednih parova modula. Drugi je korak konstruiranje tzv. dualne krivulje razvijene granične krivulje. Treći je pretvaranje dualne krivulje u blokove definirajući stvarne oblike i površine modula [54].

2.4.1.2 Stabla pretraživanja

Stabla pretraživanja (engl. *Tree Search*) je metoda prihvatljivija u smislu načina formuliranja problematike projektiranja rasporeda površina. Ovakav mehanizam pretraživanja dolazi do konstruktivnih rješenja dodavanjem jednog po jednog modula u nepotpuni prostor te vrši kontrolu ako dolazi do narušavanja postavljenih zahtjeva [55]. Međutim, ovakav pristup je svojstveno neefikasan te je često nužno unatragno

pretraživanje kada dođe do narušavanja postavljenih zahtjeva, što je vrlo kompleksan računski proces [8].

2.4.1.3 Analitički algoritmi

Analitički algoritmi (engl. Analytical Algorithms). Postoji nekolicina analitičkih tehnika koje se bave kontinuiranim projektiranjem prostora uz minimalne računske obrade [49], [56], [57], [58]. Međutim, analitički pristup mora biti dodatno unaprijeđen kako bi davao rezultate usporedive s npr. naprednim heurističkim tehnikama [58].

2.4.2 Heuristički pristupi

Donosioci odluka često pribjegavaju heurističkim pristupima pri rješavanju kompleksnih i neodređenih problema. S obzirom na upravo takvu osobinu problema projektiranja rasporeda površina ovaj pristup može biti vrlo učinkovit. Shodno tomu, veći broj heurističkih algoritama za rješavanje razmatranog problema dostupan je kroz raznu literaturu [41], [42], [59], [60], [61], [62], [63], [64], [65].

U tom pogledu, važnost učinkovitog ograničavanja inače vrlo širokih i neukrotivih područja istraživanja na neki razumni podskup mogućih topologijskih rješenja ne može se zanemariti [6], [42], [61]. U srži su ove metodologije vrlo jednostavne te se svode na tretiranje problema projektiranja rasporeda površina na problem slaganja [62]. Novije metaheurističke metode koje su pokazale dobre rezultate u rješavanju razmatranog problema uključuju metode simulacije žarišta (engl. *simulated annealing*, SA) [66], [67]; genetičke algoritme [50], [65], [68]; tabu istraživanja (engl. *tabu search*) [61]; metodu slučajnog odabira (engl. *random search*) [63], [68]; metodu prirodnog razvoja (engl. *naive evolution*) [61]; te hibridne metode [69]. Ključ ovih metodologija uglavnom leži u određenim učinkovitim sredstvima za udaljavanje od lokalnih minimuma.

Prijašnja istraživanja relativnih performansi navedenih korištenih metaheurističkih pristupa u rješavanju ovog problema daju šarolike rezultate [61], [62], [70]. Unatoč tomu, saznanja o prednostima i nedostacima pojedinih metaheurističkih pristupa mogu pomoći u pomnom izboru pristupa. Stoga će se u nastavku dati kratak osvrt na prednosti i nedostatke najpoznatijih metaheurističkih pristupa.

2.4.2.1 Genetički algoritmi

Genetički algoritmi (engl. *Genetic Algorithms*, GA) se primarno koriste zbog nedeterminističkog te globalnog pristupa optimizaciji koji osigurava približavanje optimalnom rješenju. Nadalje, genetički algoritmi omogućuju uključivanje i temeljenje istraživanja na specifičnim znanjima iz određene domene za specifičnosti pojedinačnih rješenja. Specifična znanja mogu se također upotrijebiti i u drugu svrhu kao što je selekcija te genetičke operacije [70]. Potrebno je naglasiti da GA zahtijevaju više truda u usporedbi s drugim pristupačnim metaheurističkim metodama u smislu kompleksnosti implementacije i podešavanja parametara. Međutim, GA imaju takvu svojstvenu karakteristiku da, ako ih se koristi na adekvatan način, mogu bitno utjecati na uštede kod računske obrade i zadržavaju populacije rješenja koje se simultano optimiraju. Na taj način, uzima prednosti iskustva stečenog kroz prethodne obrade te usmjerava traženje i obradu ka izglednijim rješenjima, dok operator mutacije osigurava mehanizam za udaljavanje od lokalnog optimuma [71], [72]. GA korišteni su kod problema projektiranja rasporeda površina na razne načine. Međutim većina istraživanja bavila se jednostavnijim problemima dodjeljivanja položaja jednakim modulima u zadanom prostoru. Komparativne analize genetičkih algoritama u odnosu na druge metaheurističke pristupe pokazuju njihovu superiornost za potrebe navedenog projektiranja [61]. Stoga, GA omogućuju vrlo izgledan pristup projektiranju rasporeda površina kroz generiranje najrazličitijih asortimana superiornih alternativa [27], [65], [69], [72].

2.4.2.2 Metoda simulacije žarišta

Metoda simulacije žarišta (engl. *Simulated Annealing*, SA) je vrlo znana i učinkovita stohastička tehnika optimiranja kombinatornih problema [58], [67]. SA je temeljena na usporedbi s fenomenom kristalizacije. Vrlo je učinkovita u rješavanju kompleksnih i brojnih problema u organizaciji rasporeda površina [6], [61]. Sva specifična znanja iz određene domene se većim djelom uključuju u SA funkciju cilja [70]. Ovaj pristup započinje sa nasumice izabranim rješenjem te vrši usavršavanje na način promjene lokacije modula unutar izabranog rješenja kreirajući novo rješenje. Promjene koje dovode do približavanja unutar funkcije cilja se prihvataju, dok se one promjene koje dovode do udaljavanja od funkcije cilja također prihvataju ali s vjerojatnošću da će se eksponencijalno približavati cilju u funkciji vremena. Ova je metoda poznata kao stabilan

metaheuristički pristup sposoban pronaći globalno optimalno rješenje [70]. Doduše, ona općenito vrlo sporo konvergira prema cilju u usporedbi s genetičkim algoritmima, ali kada ima dovoljno vremena na raspolaganju, ona može ponuditi rješenja usporediva s genetičkim algoritmom [61], [70]. Loša osobina ove metode je što obrađuje jedno rješenje po jedno stoga ima nedovoljna saznanja o iskustvima iz prethodnih obrada. Ukratko, *SA* se može okarakterizirati kao serijski proces koji nije prikladan proširivanju na paralelno procesiranje bez značajnih komunikacijskih dodataka [73].

2.4.2.3 *Tabu istraživanja*

Tabu istraživanja (engl. *Tabu Search*, *TS*) su još jedan uspješan, učinkovit i robustan metaheuristički pristup rješavanju kompleksnih kombinatoričkih i kontinuiranih optimizacijskih problema [70]. *Tabu* istraživanja imaju razne mogućnosti sofistikacije i prilagodbi što omogućuje njihovu široku primjenu. Općenito, *TS* je iterativni postupak koji započinje s odabranim mogućim rješenjem te nastoji pronaći bolje zamjenjujući mjesta susjednih modula. Grupa prihvatljivih rješenja obrađenih posebnom iteracijom čine listu kandidata (engl. *candidate list*) sa koje se pomoću *TS* odabire najbolji. Veličina liste kandidata rezultat je kompromisa između kvalitete i performansi [43]. Osnovna karakteristika *TS* je korištenje adaptabilnog i eksplicitnog oblika memorije u obliku tabu liste, koja služi za sprečavanje povratnih ciklusa i utjecaja na istraživanje [70]. Ukratko, ograničenja *tabua* omogućuju istraživanja izvan lokalnog optimuma uz vršenje najpovoljnijih mogućih poteza.

2.4.2.4 *Metoda prirodnog razvoja*

Metoda prirodnog razvoja (engl. *Naive Evolution*, *NE*) ima logičku podlogu sličnu onoj genetičkog algoritma. Doduše, koristi samo operator mutacije koji generira sljedeće populacije rješenja [70]. Implementacija je vrlo jednostavna. Međutim, *NE* ne posjeduje strukturirano istraživanje prouzrokovano unakrsnim operatorima kao u genetičkom algoritmu. Ali, kompleksnosti i subjektivnosti uključene u aplikacije organizacije rasporeda površina znače da se *NE* mogu koristiti kao učinkovita strategija istraživanja [61].

2.4.2.5 Metoda slučajnog odabira

Metoda slučajnog odabira (engl. *Random Search, RS*) spada u *naive* strategiju istraživanja gdje se slaganje modula generira slučajnim odabirom [61], [68]. I ova metoda također može davati dobre rezultate za kompleksne i subjektivne probleme poput projektiranja rasporeda površina. Međutim, ovi rezultati nisu dobri kao oni generirani naprednijim metaheurističkim metodama poput *GA* i *SA* [70].

2.5 Neodređenosti kod projektiranja

Iako se u polju projektiranja rasporeda površina vrše intenzivna istraživanja, ono je još uvijek nejasno i neadekvatno definirano, a postojeća literatura nudi smjernice i algoritme uglavnom bez temeljite sheme za njihovu primjenu [15], [32], [70]. Nadalje, iskoristivost ovako metodološki neizrazito strukturiranog aparata za projektiranje može biti dodatno umanjena nedovoljnom kompetentnošću projektanata.

2.5.1 Izvorišta neodređenosti

Neodređena razmatranja svojstvena za postavke kod projektiranja rasporeda površina proizlaze iz brojnih izvorišta [1], [19], [74]. U svrhu argumentacije ukratko je dano nekoliko slučajeva subjektivnih, neodređenih i proturječnih postavki u različitim kontekstima projektiranja rasporeda površina.

Kod projektiranja rasporeda površina, planiranje *a priori* zahtijeva specifikaciju ciljeva razmatranog sustava, zatim njegove primarne i sekundarne aktivnosti, međusobne odnose aktivnosti, kao i prostor potreban za njihovo odvijanje [11]. Postavke dobivene od strane eksperata u vezi međusobnih odnosa pojedinih površina mogu biti svojstveno neodređene te uzrokovane interpretacijama na različite načine od strane različitih ljudi u različita vremena. Ovakve postavke uključuju sigurnost, strukturnu cjelovitost, funkcionalnost, održivost, međusobne odnose tokova, procesa i osoblja, upravljanje, politička razmatranja, te utjecaj na okoliš [75].

Općenito, kvaliteta optimalnog ili pretpostavljenog rješenja se uvijek ocjenjuje korištenjem određenih pogodnih metrika. Budući se optimalnost kao pojam odnosi na željeni ishod uslijed određenih ograničenja ocijenjenih korištenjem specifičnih kriterija,

pogodna metrika za ocjenjivanje odabranog rješenja uključuje veći broj zahtjeva i/ili kriterija koji mogu varirati, dijelom se podudarati, ili čak biti kontradiktorni [2]. Stoga, kod projektiranja rasporeda površina, različitost, promjenjivost te nedovoljna određenost ciljeva dovodi do potrebe, pored sposobnosti projekatata i sposobnosti obrade podataka većine automatiziranih sistema za određivanje rasporeda površina, za uključivanjem u razmatranje čitavog niza podataka [6], [15]. Ova kompleksnost čini područje mogućih rješenja prilično nejasnima, što povlači za sobom potrebu za korištenjem višekriterijskih metoda odlučivanja kombinirajući različite željene karakteristike [22]. U novije vrijeme predložene su razne sheme za odgovarajuća složena višekriterijska mjerenja koja obuhvaćaju probleme procjene odabranih rješenja [70], [76].

2.5.2 Klasifikacija neodređenosti

Općenita klasifikacijska shema neodređenih postavki, ograničenja i pogodnih metrika može koristiti kao pouzdana osnova za izbor adekvatnog alata pri specifičnom razmatranju. Kao takva, neodređenost se klasificira u domeni spoznaja na kategorije znanja koja su: nepotpuna, neusklađena, neprecizna ili nejasna [9]. Pojam *nepotpunost* upućuje na nedostupnost određenih informacija odnosno na potrebu korištenja pravila aproksimativnog rezoniranja. *Neusklađenost* ukazuje na razlike ili kontradiktornosti u saznanjima proizašlim iz tumačenja dostupnih informacija u radna pravila i smjernice od strane eksperata. *Nepreciznost* se odnosi na vrijednosti koje su neprecizno ili nesavjesno određene ili pogrešno izmjerene. *Nejasnost* ukazuje na subjektivnost u procjeni određene vrijednosti ili pravila, te naglašava zapreke u adekvatnom tumačenju dostupne informacije. Općenito, smjernice, postavke i ograničenja kod projektiranja rasporeda površina su prirodno nepotpune, neusklađene, neprecizne i nejasne [15], [70], [74].

Svaka metodologija za projektiranje rasporeda površina i evaluaciju odabranih rješenja zahtjeva robustan pristup suočavanja s neodređenošću [77]. Većina metoda i tehnika smišljenih za upravljanje neodređenim informacijama su po prirodi kvantitativne. Općenito, ovakve metode i tehnike ne dozvoljavaju upadanje određenih neodređenosti unutar informacija u više od jedne gore navedene kategorije neodređenosti. U nastavku je dan kratak pregled metoda i tehnika za upravljanje neodređenostima koje se koriste u procesu projektiranja rasporeda površina, zajedno s prednostima i nedostacima.

2.5.3 Konvencionalni pristupi upravljanju neodređenostima

Potrebno je naglasiti da se ovakav visoki stupanj kompleksnosti i neodređenosti susreće i u raznim drugim poljima. Međutim, određene pojedinosti čine problem projektiranja rasporeda površina drugačijim od ostalih subjektivnih problema. Na primjer, vrhunski stručnjak iz tretirane domene često vrlo lako, na prvi pogled, može ocijeniti kvalitetu odabranog rješenja [11]. Nadalje, malo je radova dostupno vezanih za integrativni ili komparativni pregled dostupnih tehnika koje se bave rješavanjem ovakvih problema.

Prvi istraživački rad koji je koristio stohastičke parametre u projektiranju rasporeda površina, razmatrajući različite diskretne scenarije koristeći pri tome penale za najmanje vjerojatna rješenja, objavljen je 1980. godine [78]. Upravo takav pristup višestrukim diskretnim scenarijima, odnosno alternativnim rješenjima, stvorio je jezgru za daljnja istraživanja u stohastičkom planiranju rasporeda površina. Od tada objavljeno je više radova koji su koristili ideju neodređenosti u postavkama i ograničenjima kod projektiranja rasporeda površina [30], [79]. Neodređenosti koje su razmatrane u ovakvim istraživanjima imaju veća ograničenja u odnosu na neodređenosti u okolnostima u dobro definiranih događaja, poput neodređenosti kod prognoziranja. Problem projektiranja rasporeda površina također uključuje neodređenost samog događaja zbog informacija koje su nepotpune, neprecizne, neusklađene i nejasne.

Iskazane neodređenosti, te dinamika problema navedenog projektiranja zahtijevaju metodologiju primjerenu za nepotpune, neprecizne, neusklađene i nejasne postavke. Međutim, većina postojećih tehnika klasificira postavke u više kategorija istodobno. Ovaj nedostatak je izraženiji kada su informacije nepotpune [15]. Također je većina tehnika upravljanja neodređenostima prikladna samo onda kad su dostupni deterministički podaci pouzdani i pripisivi specifičnoj dinamici procesa projektiranja. Većina ovih tehnika je *ad hoc* u smislu nepostojanja naglašene teorije koja ih podržava. Takve metode mogu biti vrednovane samo kroz empirijska testiranja.

Dobro poznavanje postojećih i perspektivnih tehnika može potaknuti istraživanja neodređenosti postavki, ograničenja te ciljeva. Stoga je dan kratak pregled tehnika za modeliranje subjektivnih i neodređenih postavki kod projektiranja rasporeda površina.

2.5.3.1 Deterministički pristupi

Deterministički pristupi (engl. *Deterministic Approaches*) temelje se na pojednostavljenju pretpostavki kako bi se sve neodređene postavke lako kvantificirale i

učinile dostupnim kada su potrebne. Ovakvi pristupi obično koriste neke proizvoljne uobičajene ili očekivane vrijednosti, koje korisnik može kasnije oplemeniti uslijed interakcije s alternativnim rješenjima [6]. Međutim, većina ovih postavki je toliko zamršena da valjanost ovakvih pristupa može biti sporna. Stoga je razumljivo da su ovakvi pristupi neprikladni za kompleksne i dinamičke probleme poput projektiranja rasporeda površina. Paradoksalno, veći se dio relevantne literature temelji na ovako vrlo pojednostavljenim pretpostavkama [8], [74], [76], [80].

2.5.3.2 *Pristupi orijentirani prema korisniku*

Pristupi orijentirani prema korisniku (engl. *User-Oriented Approaches*) slično kao i kod determinističkih pristupa uzdaju se u ručno pribavljenim omjerima, postavkama i karakteristikama ulaznih podataka od strane korisnika. Iako ovakvi pristupi daju veći stupanj prilagodljivosti i nadzora, korisnici su obično pretrpani brojnim podacima te ograničeni saznanjima iz specifične domene. Stoga je korisnost ovakvih pristupa bitno ograničena u traganju za rasprostranjenim kognitivnim, ekonomskim i ostalim izvorima zahtjeva. Nadalje, ponekad nije moguće naći eksperta iz određene domene koji bi pribavio tražene ulazne podatke. Ovakav se pristup smatra neprilagodljivim i neproduktivnim [11].

2.5.3.3 *Pristupi temeljeni na ograničenjima*

Pristupi temeljeni na ograničenjima (engl. *Constraint-Based Approaches*) poput predstavljanja znanja i strategije zaključivanja široko su primjenjivane na automatiziranom grafičkom projektiranju rasporeda površina [81]. Ograničenjima se dolazi do snažnog, ali jednostavnog formalizma specificiranja postavki u ovim dinamičkim domenama [82]. Dokazano je da objektivna, međuodnosna, prostorna, vremenska i druga ograničenja mogu prikazati kompleksne postavke na prilagodljiv, intuitivan i deklarativan način [83]. Ovakav pristup može rezultirati pojednostavljenjem opaženih neformalnih postavki unutar domene [84]. Primjerice, odnos između dvije određene kategorije modula može biti određen korištenjem jedne jedine grupe zahtjeva. Shodno tomu, u širem smislu, ovakvi pristupi su bliski pristupima koji se temelje na saznanjima. Ipak cilj ovakvih pristupa je provedivost, a ne udovoljavanje i zadovoljavanje kao u većini pristupa temeljenih na saznanjima. Iako su radovi koji tretiraju ovu tematiku više teorijskog karaktera, prošireni pregled ovakvih pristupa dostupan je u [81], [84].

2.5.3.4 *Matrice tokova*

Matrice tokova (engl. *From-To Chart, FTC*) su jedan od najpouzdanijih alata korištenih u projektiranju rasporeda površina za dobivanje ulaznih parametara u pojednostavljenom obliku za potrebe kompjuteriziranih sistema [11]. Uobičajeno sadrže brojeve koji predstavljaju veličinu interakcije između para modula. Primjerice, mogu sadržavati mjeru vezanu za materijal, osoblje te tok informacija između dva odjeljka u kontekstu rasporeda površina. Ove se veličine u konačnici pretvaraju u neku vrstu mjere koja daje ocjenu bliskosti (engl. *Closeness Rating*). Unatoč tomu što je bio zamišljen da opisuje kvantitativne vrijednosti, *FTC* se često koristio i za opisivanje kvalitativnih vrijednosti [85]. Ova metoda daje vrlo kruta i okvirna rješenja, međutim dobra za preliminarna razmatranja.

2.5.3.5 *Izrada tablica odnosa*

Izrada tablica odnosa (engl. *Relationship Chart, REL*) među aktivnostima je jedna od najkorištenijih tehnika za izražavanje neodređenih postavki [6]. U pravilu, odnosi među aktivnostima se pretvaraju u relativne neposredne zahtjeve između dva para modula čije se pozicije moraju odrediti. *REL* je zamišljen kao pomoć pri razmatranju kvalitativnih faktora, političkih potreba ili dinamičkih situacija gdje je nemoguće doći do točnih podataka zbog vremenskih, financijskih i drugih praktičnih ograničenja [11].

2.5.3.6 *Kompjutorske simulacije*

Kompjutorske simulacije (engl. *Computer Simulations*) predstavljaju korisnu alternativu u nedostatku ostalih prikladnih funkcija [86]. Ovakav pristup osigurava detaljnu analizu, modeliranje i evaluaciju kompleksnih problema projektiranja rasporeda površina [87]. Međutim, simulacijski modeli nisu lako prilagodljivi optimizaciji i izmjenama te je dobivanje alternativnih rješenja otežano [88]. U posljednje vrijeme određeni napori učinjeni su u optimizaciji simulacijskih modela koristeći genetičke algoritme u raznim kontekstima projektiranja s ciljem unapređenja procesa i osiguravanja kvalitetnijih rješenja [87]. Međutim, na kompjutorske simulacije se obično troši previše vremena, stoga se rijetko koriste kod ovakvih problema.

2.5.4 Računalni pristupi upravljanju neodređenostima

Većina metodologija za upravljanje neodređenostima kroz aproksimativno rezoniranje su uglavnom kvantitativne prirode. U takvim pristupima neodređenosti se kvantificiraju u obliku određenih mjera koje se propagiraju kroz fazu zaključivanja [89], [90]. Primjeri uključuju *Bayes-ove mreže*, faktore izvjesnosti, teoriju *Dempster-Shafer*, itd. Ključna stavka pri korištenju ovakvih kvantitativnih pristupa jest točnost predstavljanja vjerojatnosti ili pak zavisnosti u zadanoj domeni. U nastavku je dan kratak opis najkorištenijih računalnih pristupa upravljanju neodređenostima.

2.5.4.1 Bayes-ove mreže

Bayesove mreže (engl. *Bayesian Networks*, *BN*) se koriste za formiranje politike upravljanja neodređenostima unutar informacija. *BN* je probabilistički pristup koji se temelji na Bayesovom teoremu gdje se očitosti kodiraju u usmjereni aciklički graf u kojemu čvorišta predstavljaju varijable a veze odgovaraju utjecajima probabilističkih odnosa [91]. *BN* zahtjeva velik broj vjerojatnosti te stoga i velik broj eksperimenata. Zato je ovakav probabilistički pristup pogodan kada postoji neodređenost u samoj pojavi određenog događaja [38]. Ali, ovakav je pristup valjan samo uslijed određenih pojednostavljenih pretpostavki [9]. Zaključno, *BN* je prilično neprikladan pristup koji ne osigurava dovoljno obrazloženja za odabrano rješenje koja su ključna kod neodređenih domena [89].

2.5.4.2 Faktori izvjesnosti

Faktori izvjesnosti (engl. *Certainty Factors*, *CF*) su još jedan kvantitativni pristup modeliranju problema neodređenosti. Kod ovog pristupa spoznaje su izražene u obliku pravila kojima se dodjeljuje faktor povjerenja. Ovaj je pristup još jedan *ad hoc* režim koji nije izgrađen na jasnim teorijskim osnovama. Često se uočavaju mnogi nedostaci u postupku rezoniranja [9]. Primjerice, *CF* pristup radi pod implicitnom pretpostavkom nezavisnosti od hipoteze, što je često krivi postulat. Nadalje potreba za većim brojem ulaznih podataka postaje glavna preokupacija korisnika [11].

2.5.4.3 Demmpster-Shafer teorija

Demmpster-Shafer teorija dokazivanja (engl. *Demmpster-Shafer Theory, DS*) adresira određene slabosti probabilističkih pristupa uključujući prikazivanje neupućenosti, nepotrebne zahtjeve, itd. *DS* je primjenjivan za kvantitativno modeliranje postavki u situacijama kada su djelomično ili potpuno nedostajali statistički podaci kako bi se procijenio učinak novih opažanja na rezultirajuću ocjenu. Međutim, ono ne precizira kako procijeniti vjerojatnosti ili interpretirati rezultate, pa se u određenim slučajevima, očito mogu očekivati krivi rezultati [9]. Dakle, *DS* je također ad hoc pristup i kao takav nije pogodan za problem projektiranja rasporeda površina.

2.5.4.4 Neizrazita logika

Neizrazita logika (engl. *Fuzzy Logic, FL*) je set formalnih matematičkih principa, pomoću kojih se može osigurati metodologija za prikazivanje, manipulaciju i implementaciju ljudskog (ekspertnog) znanja. Ona modelira kognitivne neodređenosti, mišljenja te odluke inficirane nepotpunošću, neusklađenošću, nepreciznošću te nejasnoćom [92]. Ljudi često rezoniraju uvjetovani nejasnim i dodatno uvjetovanim konceptima u bavljenju neodređenim situacijama [4]. Primjerice, eksperti mogu opisati postavke s obzirom na količinu neiskorištenih površina unutar prostora u kontekstu *FL* kao „slabe“, „srednje“ i „jake“. Stoga se *FL* pokazala kao učinkovita i robusna tehnika u raznim poljima gdje se suočava s nepotpunim, neusklađenim, nepreciznim i nejasnim informacijama [9]. Zaključno, ona se pokazala superiornom naspram ostalih alata koji upravljaju neodređenostima u kontekstu računalne kompleksnosti.

2.5.5 Usporedba pristupa za upravljanje neodređenostima

S ciljem dobivanja komparativne procjene nekih prethodno spomenutih pristupa izvršeno je istraživanje [11]. U tom istraživanju, vrloiskusni istraživači u razmatranom polju rangirali su prethodno navedene pristupe za upravljanje neodređenostima ocjenama od 1 do 10, s obzirom na razne kriterije evaluacije. Dobiveni rezultati su obrađeni i prosječne ocjene dane u tablici 3.1.

Tablica 2.1. Prosječne ocjene pristupa za upravljanje neodređenostima kod projektiranja rasporeda površina prema kriterijima evaluacije [11].

Pristup	Kriterij evaluacije						
	<i>Upoznatost</i>	<i>Lakoća poimanja</i>	<i>Lakoća korištenja</i>	<i>Prilagodljivost</i>	<i>Moć izražavanja</i>	<i>Robusnost</i>	<i>Podatnost</i>
Deterministički	9,6	9,9	8,3	3,7	3,1	1,2	2,9
Korisniku orijentiran	9,5	8,6	6,3	3,9	3,8	3,6	2,0
Tablica odnosa	9,0	8,0	6,5	6,0	5,5	5,3	4,8
Bayesov	7,2	3,5	3,5	2,3	4,3	3,2	2,8
Faktori izvjesnosti	8,1	6,7	5,9	4,3	5,8	5,1	6,5
Dempster-Shafer	7,1	5,1	3,7	3,7	4,2	3,8	4,4
Neizrazita logika	7,3	7,2	6,9	7,3	7,5	7,8	6,3
Simulacija	5,8	2,9	1,7	1,4	6,9	2,2	1,8

Među navedenim kriterijima evaluacije *lakoća poimanja* ima glavnu ulogu u izboru određenog pristupa. Još jedan odlučujući kriterij evaluacije, bitan za uspješnost primjene određene metodologije, jest *prilagodljivost*. Taj kriterij se odnosi na lakoću modificiranja određenih parametara i komponenti sistema uslijed dinamičkih zahtjeva ili uslijed analize različitih scenarija. *Robusnost* predstavlja sposobnost pouzdanog i učinkovitog rada metodologije u promjenjivim situacijama, te je također jedan od ključnih faktora za uspješnost njene primjene u domenama koje sadrže subjektivne, neodređene i dinamičke probleme.

Intuitivno, deterministički i korisniku orijentirani pristupi, procijenjeni su kao najjednostavniji za razumijevanje i primjenu. Međutim ove tehnike su procijenjene kao loše u pogledu prilagodljivosti, moći izražavanja, robusnosti i podatnosti, koji su vrlo bitni faktori u određivanju primjenjivosti i učinkovitosti pojedinih pristupa. Nadalje ovakve tehnike nisu valjana opcija za probleme koji sadrže široki spektar informacija.

Slično tomu, kompjutorska simulacija ocijenjena je s najnižim ocjenama zbog potrebe ulaganja prevelike količine vremena za simulacijsko modeliranje, kao i zbog komplikacija uslijed izmjena različitih scenarija. Neizrazita logika ocijenjena je visokim ocjenama zbog svoje učinkovitosti.

2.6 Automatizirano projektiranje

Automatizacija procesa projektiranja rasporeda površina kroz kompjuterizirano osnivanje, evaluaciju i filtriranje superiornih alternativnih rješenja od strane donosioca odluka smatra se fundamentalnim dijelom u bilo kojem procesu planiranja rasporeda površina [6], [18], [76]. Većina dostupnih kompjuteriziranih alata za projektiranje rasporeda površina podrobnija je od običnog CAD crtanja i dokumentacijskih pomagala [6], [8], [76]. Razumljivo, najviši stupanj kompleksnosti, neodređenosti te brojnost postavki i zahtjeva, zadržali su istraživanje problema projektiranja rasporeda površina u analitičkom obliku [58], [76].

Istraživanja u području projektiranja rasporeda površina rezultirala su raznim sistemima za automatizirano projektiranje. Takvi sistemi imaju svoje prednosti i nedostatke.

2.6.1 Postojeći sistemi

Osnovne domene u kojima se koriste postojeći sistemi za automatizirano projektiranje rasporeda površina su: proizvodni sustavi i građevine (engl. *Facilities Layout*), elektronički sklopovi (engl. *Circuit Layout*), te vizualna sučelja (engl. *Visual interface Layout*). Unatoč svim tvrdnjama o prilagodljivosti i superiornosti, postojeći automatizirani sistemi projektiranja sadrže značajna ograničenja sa raznih stajališta. Zaključeno je da se kao takvi mogu upotrijebiti kao prvi filter u izboru većeg broja superiornih rješenja koje će se dodatno analizirati određenim metodologijama te je upravo strukturiranje jedne takve metodologije i tema ovoga rada. U nastavku su navedeni postojeći sistemi za automatizirano projektiranje rasporeda površina, ali samo za domenu interesa, odnosno za automatizirano projektiranje rasporeda površina proizvodnih sustava i građevina.

Razvoj i primjena sistema za automatizirano projektiranje rasporeda površina proizvodnih sustava i građevina (engl. *Facilities Layout Design*) započela je u ranim šezdesetim godinama prošlog stoljeće. Tada je samo nekoliko takvih sistema bilo dostupno na tržištu, od kojih se nisu svi istakli u primjeni [6]. Do danas je osnovan značajan broj takvih sistema, ali se samo sljedeći još primjenjuju bez obzira na godinu proizvodnje: CRAFT [93], CORELAP [94], ALDEP [95], SPACECRAFT [96], FLING [7],

MOCRAFT [97], BLOCKPLAN [98], LayOPT [99], CLASS [100], MULTIPLE [29], EDSLP [101], FactoryOpt [102], FACOPT [103], VIP-PlanOpt [104]. Kao što je već spomenuto, većina postojećih sistema za automatizirano projektiranje ne odgovara relativno zahtjevnijim projektima projektiranja proizvodnih sustava i građevina. Nadalje, samo nekolicina komercijalno dostupnih sistema uključuje generiranje rasporeda površina, dok uglavnom većina daje neku vrst evaluacije povezanu sa skicom [29]. Osim za nekoliko novijih sistema, analiza mogućnosti, ograničenja i karakteristika ostalih sistema mogu se pronaći u [105].

2.6.2 Ograničenja postojećih sistema

Unatoč mnogim unapređenjima i inovacijama u sistemima za automatizirano projektiranje, ključna problematika je uglavnom ostala ista [6], [8], [19]. Iako postojeći sistemi sadrže svojstvene prednosti i nedostatke, oni su svi općenito neprilagodljivi te ne mogu rješavati veće probleme. Nedostaci postaju očitiji kada se uoči da većina aplikacija za projektiranje rasporeda površina nije dobro definirana. Ovakve slabo strukturirane aplikacije uključuju visoki stupanj neodređenosti. U nastavku su dani kratki komentari ograničenja postojećih sistema.

Prilagodljivost jest nedostatak svih sistema za automatizirano projektiranje layout-a. Jedan od razloga tomu jest krutost parametara na osnovu kojih se generiraju alternativna rješenja rasporeda površina [30], [76], [86]. Većina postojećih sistema pristupa problemu projektiranja kao problemu optimizacije odabranim krutim kriterijem. Superiornost rješenja je često određena mnoštvom konkurentnih kriterija.

Kreativnost. Metode upravljanja podacima kod većine postojećih sistema za automatizirano projektiranje pogodne su samo za pouzdane determinističke podatke koji su dostupni i dodjeljivi specifičnoj aktivnosti. Ipak, ovakvi podaci ili ne postoje ili postoje za neke projektne nepostojeće i nerealne uvjete modeliranja. Dakle, učinkovita sredstva za analizu i reviziju rješenja kroz uključivanje projektantovih intuicija, kreativnosti i ekspertiza su u stvarnosti ne-egzistentna. Ovakva nemogućnost uvažavanja manje formalnih i intuitivnih podataka rezultiraju zatajenjem vitalnih dinamika procesa [80].

Produktivnost postojećih sistema za automatizirano projektiranje, mjerena u brzini potrebnjoj za generiranje superiornih alternativnih rješenja, još je jedno pitanje koje privlači pozornost. Brzina, odnosno sporost podređenih sistema predstavlja jednu od najvećih prepreka za njihovu primjenu [8]. Iskustva su pokazala da je VIP-PlantOpt [104]

superioran u odnosu na ostale postojeće sisteme za automatizirano projektiranje u pogledu brzine te sposobnosti savlađivanja zahtjevnih problema [11]. Međutim, i ovaj sistem sadrži određena ograničenja u pogledu prilagodljivosti i primjenjivosti u većini situacija u praksi. Prema tome, postoji značajna potreba za prijedlogom i razvijanjem robusne metodologije za tretiranje problema projektiranja rasporeda površina.

Stupnjevitost. Primjenjivost postojećih sistema za automatizirano projektiranje dodatno je ograničena nemogućnošću razmatranja većeg broja modula u fazi odlučivanja [8]. Ovakvi sistemi često nisu u mogućnosti rješavati realne probleme. Primjerice, problemi koji sa više od 40 modula sve do nedavno nisu bili objavljeni u literaturi [30], [61], [104].

2.7 Perspektivne računalne tehnike i alati

U ovom odlomku dan je kratak pregled računalnih tehnologija koje se drže korisnim za dobivanje inteligentne podrške u odlučivanju kod projektiranja rasporeda površina. Inteligentni sistemi su projektirani kako bi rješavali probleme koji najčešće nemaju jasno definirane dobre ili loše izvedbe [92], [106]. Zajednički nazivnik u računalnim tehnikama jest njihova različitost od klasičnog razmišljanja i pristupa modeliranju [92]. Osnovne komponente računalnih tehnika su metode poput neizrecive logike, genetičkih algoritama, teorije odlučivanja, ekspertnih sistema, teorije kaosa itd.

Ovakve metode mogu pružiti sredstva za oponašanje impresivne ljudske sposobnosti za izražavanjem znanja kroz lingvistički prikaz informacije. Ovakvi pristupi prihvaćaju se za modeliranje spoznaja, inteligentne sisteme i umjetne inteligencije jer su uključene procedure vrlo slične ljudskom zaključivanju. U nastavku će se dati glavne značajke nekih relevantnih alata koje predstavljaju perspektivne izbore za daljnja istraživanja kod problema projektiranja rasporeda površina u brodogradnji.

2.7.1 Genetički algoritmi

Genetički algoritmi (engl *Genetic Algorithms*, *GA*) su motivirani procesom biološke reprodukcije oponašajući prirodnu selekciju i biološku evoluciju. *GA* objedinjuju ideju „opstanka najjačega“, nasumično ali ipak strukturirano istraživanje, te usporedna procjena čvorišta u prostoru istraživanja [106]. Tipični ciklus evolucije *GA* sastoji se u

generiranju rješenja od kojih su neka definirana kao roditelji u genetičkoj evoluciji. Genetička evolucija rezultira novom generacijom rješenja te se ciklus ponavlja.

Kodiranje varijabli, jednostavnost i lakoća operacija, minimalni računalni zahtjevi, nasumična početna populacija, pogodnost za paralelno procesiranje, robusnost, neovisna kontrola aspekata istraživanja, te globalna perspektiva, učinila je *GA* primjenjivim na razne domene. Nekolicina ovih prednosti je, eksplicitno ili implicitno, proizašla iz populacijski temeljenog istraživanja gdje *GA* utvrđuje sljedeće točke istraživanja koristeći pogodne vrijednosti trenutnih točaka istraživanja koje su rasprostranjene u prostoru koji se istražuje. *GA* su pokazali snagu u rješavanju zahtjevnih problema što ih je učinilo dobrim izborom za podršku u odlučivanju kod projektiranja rasporeda površina zbog svojeg spretnog određivanja populacije ili niza superiornih rješenja.

Dostupan je čitav niz literature koja sadrži primjenu *GA* za projektiranje rasporeda površina u raznim domenama i na različite načine [30], [53]. Poglavitito, *GA* su pokazali nadmoć nad ostalim metodama rješavanja problema projektiranja zbog brzine i efikasnosti [61]. Detaljni pregled istraživanja vođenog u ovom smjeru može se naći u [107].

2.7.2 Umjetne neuronske mreže

Tradicionalni sustavi temeljeni na znanju ne mogu učiti i unapređivati se kroz iskustvo. No automatizirani mehanizam učenja može unaprijediti brzinu i kvalitetu kroz usvojena znanja. Svojstvenost učenja Umjetnih neuronskih mreža (engl. *Artificial Neural Networks*, *ANN*) kroz povijesne slučajeve može automatski generirati pravila, te na taj način izbjeći mučne i skupe procese usvajanja, procjene i revizije znanja. *ANN* predstavljaju kategoriju snažnih i opće primjenjivih alata koji pokazuju veliku perspektivu na različitim primjenama [108]. Otkriće ove paradigme i obrade informacija inspirirano je strukturom i funkcijom ljudskog mozga, a sastoji se od broja jednostavnih i vrlo povezanih procesora nazvanih *neuronima*. Ti neuroni povezani su sa ponderiranim vezama koje prenose signale s jednog neurona na drugi i na taj način *ANN* uči kroz ponavljano usklađivanje pondera. Ti ponderi implicitno pohranjuju znanja potrebna za rješavanje specifičnog problema [109].

2.7.3 Metoda učenja pojačavanjem

Metoda učenja pojačavanjem (engl. *Reinforcement Learning*, *RL*) predstavlja još jedan obrazac za mehaničko učenje koji nastoji učiti od okoline i njemu prilagoditi sistem. *RL* može pomoći kod automatskog usavršavanja i poboljšanja znanja ili postavki kontinuiranim nadziranjem interakcije projektanta sa dostupnim alternativnim rješenjima. Posljedično, *RL* može biti vrlo koristan kod slabo evoluirajućih scenarija, reducirajući potrebu za zamornim revizijama baze znanja. Međutim, teško se mogu pronaći radovi vezani uz *RL* s primjenom na problem projektiranja rasporeda površina.

2.7.4 Sustavi temeljeni na znanju

Razni sustavi temeljeni na znanju (engl. *Knowledge-Based Systems*, *KBS*) poput sustava podrške odlučivanja (engl. *Decision Support Systems*, *DSS*) i ekspertnih sustava (engl. *Expert Systems*, *ES*), uspješno su razvijeni u raznim domenama unutar kojih se susreću subjektivni i neodređeni podaci [4], [6]. Doista, znanje se smatra jedinim faktorom proizvodnje koji nije podvrgnut smanjenju prinosa [110]. Unatoč dostupnoj literaturi koja opisuje razne *DSS* i *ES* s primjenom na problem projektiranja rasporeda površina, smatra se da je realni potencijal ovakvih snažnih sustava još neistražen [11]. Postojeći sustavi temeljeni na znanju kod projektiranja koriste ograničene mogućnosti sustava podrške odlučivanja i ekspertnih sustava. Unatoč tomu, smatra se da su ovakvi sustavi vrlo vrijedni u kontekstu projektiranja rasporeda površina.

2.8 Sažetak

U ovom je poglavlju dan pregled poznatih pristupa i tehnika kao i dostupne literature u domeni relevantnoj za projektiranje rasporeda površina. Identificirani su ključni nedostaci vezani uz samu problematiku te uz postojeće metode, tehnike i alate projektiranja u općem smislu. Također je opisana nekolicina perspektivnih alata pomoću kojih se dolazi do željenih ciljeva. Nadalje, identificirane su ključne prednosti takvih alata koje ih čine perspektivnim za odabir. Ne temelju izvršenog pregleda dosadašnjih istraživanja, spoznaja i dostignuća kroz dostupnu literaturu može se utvrditi da su ista razvijana u različitim domenama, ali ne i u brodogradnji. Zaključno, u brodogradnji se za

rješavanje prethodno navedenih problema ne koriste dovoljno suvremene metode primijenjenih operacijskih istraživanja, kako bi se odredila optimalna projektna rješenja. Stoga se na temelju izvršenog istraživanja kroz dostupne izvore, te uz posebne spoznaje dobivene participacijom na projektima za gospodarstvo, izvršio izbor prikladnih metoda, tehnika i alata čije skupne prednosti u točno definiranoj proceduri projektiranja tvore novu posebno strukturiranu metodologiju za projektiranje rasporeda površina primjenjivu na specifičnom primjeru kao što je brodogradilište.

3 CILJ ISTRAŽIVANJA

Pregledom dostupnih izvora uočeno je da se u brodogradnji napredne metodologije ne koriste u dovoljnoj mjeri, a poglavito za projektiranje optimalnog rasporeda proizvodnih površina. Stoga je odlučeno pristupiti istraživanju s ciljem prijedloga nove metodologije za projektiranje optimalnog rasporeda proizvodnih površina brodogradilišta te pripadajućih proizvodnih tokova. U ovom je poglavlju opisano područje istraživanja te postavljanje cilja istraživanja.

3.1 Područje istraživanja

Proizvodne površine u brodogradnji od posebnog su značaja zbog same specifičnosti ove proizvodne djelatnosti gdje vrlo velike dimenzije proizvoda uvjetuju angažiranje velikih površina. Interes za istraživanje problema projektiranja i optimizacije rasporeda proizvodnih površina proistječe iz nekoliko osnovnih razloga:

- I. Veličina i oblik površine u brodograđevnom procesu strogo su fiksirani lokacijom brodogradilišta koju najčešće s jedne strane omeđuje vodena površina, a sa kopnene urbana ili industrijalizirana sredina. Rijetke slobodne površine predviđene za razvoj najčešće su već iskorištene ranijim rekonstrukcijama tih pogona.
- II. Raspored postojećih brodograđevnih pogona, zbog krupnih građevinskih objekata, najčešće nije prilagodljiv i prikladan za promjene.
- III. Vrlo intenzivni razvoj tehnologije gradnje broda postavio je zahtjeve na proizvodne površine u brodogradilištima koji se zbog postojećih ograničenja teško mogu implementirati.

Za postojeća brodogradilišta jedna od prepreka u očekivanom razvoju brodograđevne proizvodnje, kako je već spomenuto, zasigurno je prostorno ograničenje. Stoga je kod njih nužno tražiti način da dalje unapređuju svoju proizvodnju i uz to održe konkurentnost na svjetskom tržištu. U tim brodogradilištima tehnološka modernizacija mora biti usmjerena prema intenziviranju korištenja postojećih prostornih resursa u svrhu unapređenja proizvodnih tokova.

Opća karakteristika u razvoju brodograđevne tehnologije u prošlosti bilo je nastojanje da se osigura što više radnih površina kao prirodan odgovor na stalan rast jedinica koje su se gradile i sve kraćih rokova njihove isporuke. To je i dovelo do problema nedostatka prostora za daljnji razvoj u tom pravcu. Iako se ne može reći da se u brodogradilištima nije radilo na intenziviranju korištenja postojećih prostora, ipak razvoj tehnologije nije vodio dovoljno računa o tom faktoru. Nesumnjivo je da će razvoj brodograđevne tehnologije u narednom periodu stavljati u primarne zadatke potrebu optimizacije proizvodnih površina.

S obzirom da se nova brodogradilišta u *EU* ne grade, ili se iznimno grade, postavlja se vrlo aktualno pitanje o pravcima razvoja brodograđevne djelatnosti da bi proizvodnja u postojećim europskim brodograđevnim pogonima, u danim prostornim ograničenjima, po kapacitetu i brzini isporuka na racionalnoj osnovi mogla i u budućnosti pratiti zahtjeve svjetskog tržišta. Jedno od rješenja jest usmjeravanje razvoja brodograđevne tehnologije prema optimalnom korištenju postojećih proizvodnih površina u brodogradilištima.

Visoka investicijska ulaganja, koja zahtijeva izgradnja novih brodogradilišta, povezana s velikim poslovnim rizicima i relativno malom akumulativnošću brodogradnje u normalnim tržišnim uvjetima, upućuje na neophodnost traženja rješenja prvenstveno u okvirima postojećih brodogradilišta, usavršavanjem i daljnjim razvojem postojećih tehnoloških kapaciteta. Uočavanje novih mogućnosti u razvoju brodograđevne tehnologije doprinijet će također racionalnijem restrukturiranju postojećih brodogradilišta.

Nužne su i promjene u koncepciji dugoročnog razvoja kako sredstava pomorskog transporta tako i tehnologije u njihovoj proizvodnji.

Jedan od razloga sporijeg rasta proizvodnih snaga u brodogradnji je još i u danas prisutnoj logici razvoja brodogradnje koja je isključivo polazila od zahtjeva za proizvodnjom plovniha objekata, definiranih po narudžbi od brodovlasnika ili korisnika, što je nužno uvjetovalo pojedinačnu, ili proizvodnju manjih serija brodova. Kod toga se mogu izdvojiti pojedina brodogradilišta, pretežno u Japanu i Skandinaviji, koja su se specijalizirala za određene tipove brodova, kao što su *VLCC* ili *LNG i LPG* brodovi te su za gradnju takvih tipiziranih jedinica razvila visoko produktivna sredstva i metode. Takva bi brodogradilišta trebala uzeti kao primjer smjera razvoja i hrvatskih brodogradilišta.

Realizacija takve tipske proizvodnje plovniha objekata, odnosno njihovih tipiziranih modularnih dijelova, otvara nove mogućnosti industrijalizacije brodogradnje i u tom pravcu nužno je istražiti koje opće važeće zakonitosti implicira transfer suvremenih industrijskih metoda u prostorna ograničenja postojećih hrvatskih brodogradilišta.

3.2 Postavljanje cilja istraživanja

Razvoj tehnologije gradnje broda direktno se odražava na izmjene u koncepciji proizvodnog procesa, što nužno uvjetuje potrebu reorganizacije rasporeda površina.

Poznato je, da je jednostavnije udovoljiti zahtjevima koje postavlja suvremena tehnologija kod projektiranja novih, nego kod projektiranja postojećih brodogradilišta, koja zahtijevaju prilagodbe novom tehnološkom procesu i tehnologiji rada kako bi održala konkurentnost na svjetskom tržištu. U pravilu, uspješno i racionalno rješenje teže je naći što je starije postrojenje koje treba prilagoditi odnosno tehnološki modernizirati. Glavninu hrvatskih brodograđevnih kapaciteta predstavljaju upravo stariji pogoni, izgrađeni na temeljima tradicionalne brodograđevne tehnike i proizvodne koncepcije, koju je karakterizirala pojedinačna i pretežno zanatska tehnologija i organizacija rada, stoga je izrada projekta njihove tehnološke modernizacije vrlo složen proces.

Osnovni problem pri tehnološkoj modernizaciji postojećih brodogradilišta jest prostor. Slobodnih i raspoloživih površina najčešće nema i nužno je prići tehnološkoj modernizaciji sa stajališta pronalaženja novih proizvodnih tokova brodograđevnog proizvodnog procesa kroz optimizaciju rasporeda proizvodnih površina.

Stoga, osnovni cilj istraživanja jest osnivanje i prijedlog posebne metodologije za projektiranje optimalnog rasporeda proizvodnih površina brodogradilišta, koja bi omogućila ispitivanje mnogih varijanti rješenja, u okvirima virtualnog modela na računalu, u ranijoj fazi projektiranja i bez involviranja većih financijskih sredstava, a zatim bi omogućila odabir optimalnog rješenja temeljem postavljenih kriterija.

Primjena predložene metodologije projektiranja rezultirala bi racionalnim investicijama za tehnološke obnove postojećih brodogradilišta zbog optimalnih rješenja rasporeda površina te proizvodnih tokova sukladno postavljenim kriterijima, dajući upravama veću pouzdanost kod donošenja odluka.

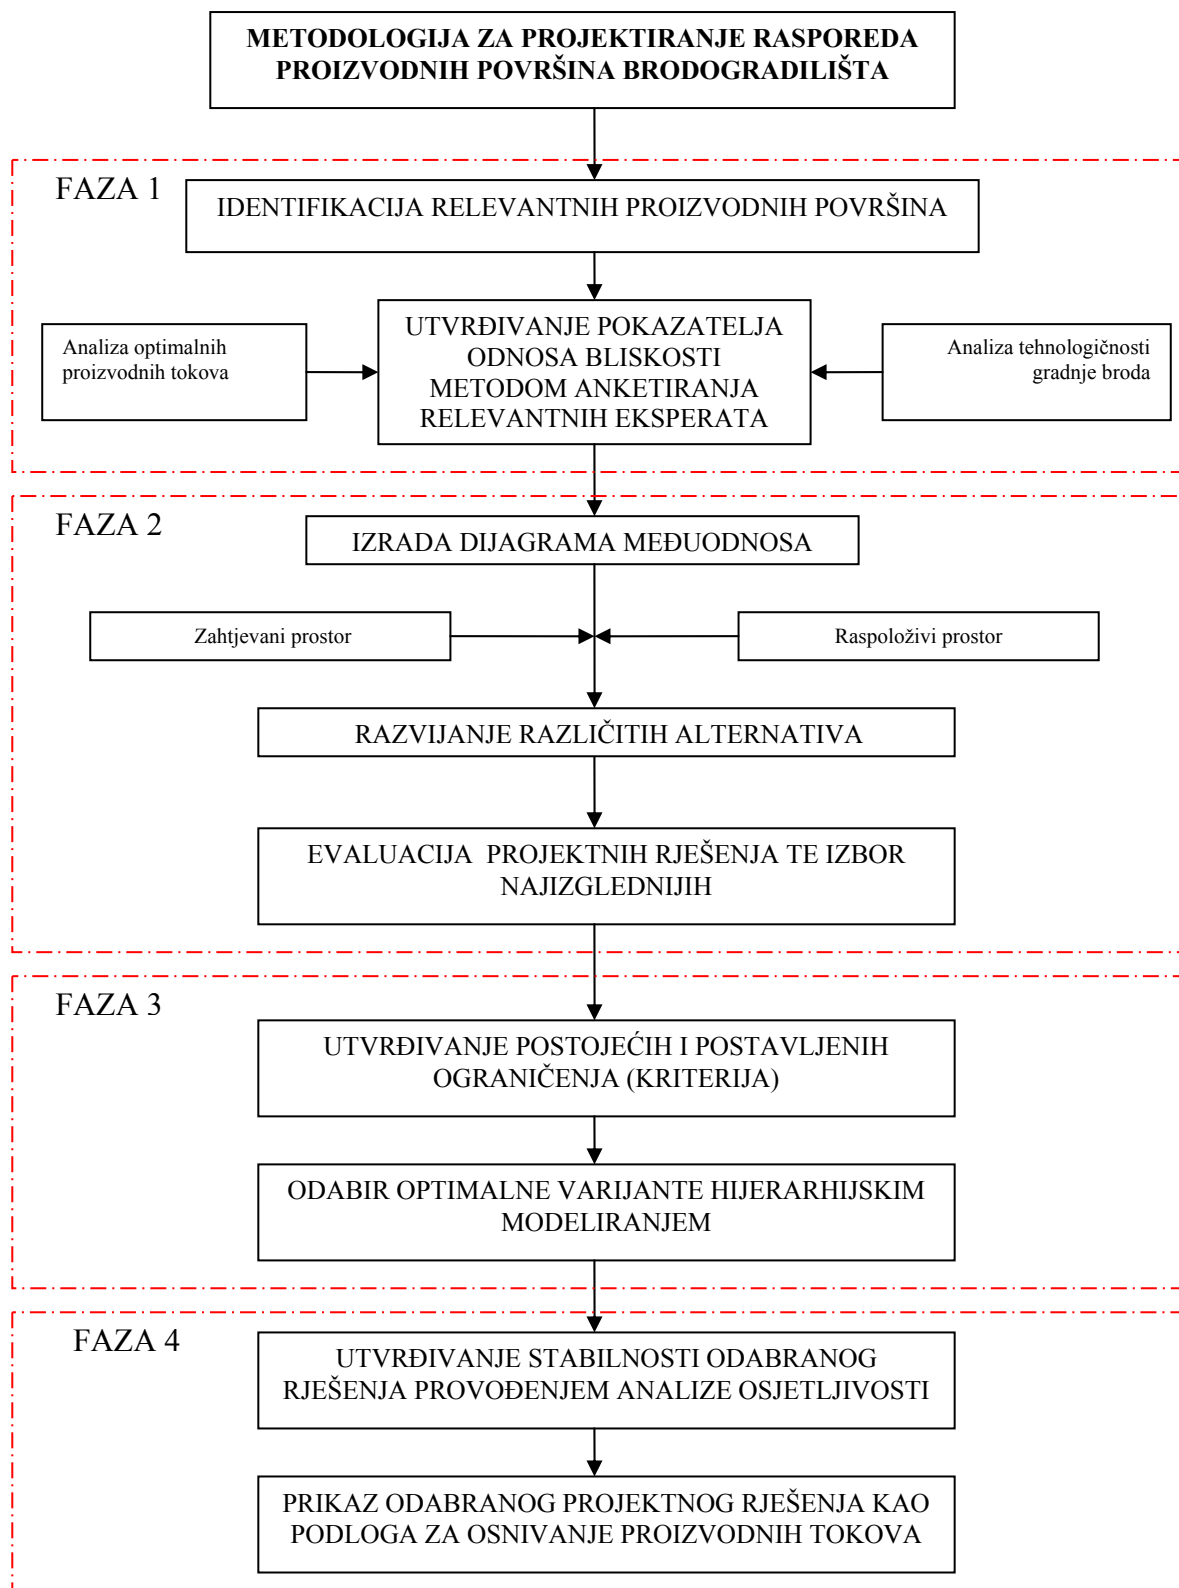
Upravo radi što boljeg vrednovanja predložene metodologije ista je primijenjena na jednom postojećem brodogradilištu u okviru tehnološkog projekta njegove modernizacije.

4 PRIJEDLOG METODOLOGIJE ZA PROJEKTIRANJE OPTIMALNOG RASPOREDA PROIZVODNIH POVRŠINA BRODOGRADILIŠTA

Temeljem usvojenih znanja kroz znanstveno i stručno usavršavanje tijekom poslijediplomskog studija te dodatnih posebnih znanja usvojenih participacijom u projektima za privredu, a poglavito participacijom na projektu tehnološke modernizacije postojećeg brodogradilišta došlo se do zaključka o nedostatku adekvatne metodologije za projektiranje, modernizaciju ili optimizaciju rasporeda proizvodnih površina te pripadajućih proizvodnih tokova. Iz navedenog razloga ista je osmišljena, predložena i objašnjena u ovom poglavlju.

Predložena metodologija za projektiranje rasporeda proizvodnih površina zasniva se na provođenju točne procedure koja se sastoji od četiri faze kroz koje se dolazi do optimalnog projektnog rješenja. U prvoj fazi, definirane su relevantne proizvodne površine te su korištenjem metode anketiranja, provedene među relevantnim ekspertima, utvrđeni posebni težinski faktori, tj. ponderi kojima se definiraju pokazatelji odnosa bliskosti definiranih proizvodnih površina, a sa stajališta optimalnih tokova osnovnog brodograđevnog procesa. Utvrđeni ponderi predstavljaju poseban doprinos jer ih je moguće primjeniti za bilo koji brodograđevni proizvodni proces na kojemu se primjenjuje predložena metodologija. Nadalje, u drugoj fazi predlaže se generiranje svih mogućih varijanti rasporeda odabranih proizvodnih površina u okvirima brodogradilišta korištenjem *SLP* metode (engl. *Systematic Layout Planning*). Temeljem utvrđenih težinskih faktora iz prve faze, svaka se generirana varijanta u okviru ove metode ocjenjuje tzv. *SLP* ocjenom rasporeda površina. Temeljem navedene ocjene se predlaže odabir najizglednijih varijanti rasporeda površina za detaljnu analizu koja slijedi. U trećoj fazi, utvrđuju se postojeća i postavljena ograničenja (tzv. kriteriji) na temelju kojih se hijerarhijskim modeliranjem uz korištenje *AHP* metode (engl. *Analytic Hierarchy Process*) vrši analiza i odabir optimalne varijante kao konačnog projektnog rješenja rasporeda proizvodnih površina. Zaključno u četvrtoj fazi vrši se utvrđivanje stabilnosti projektiranog rasporeda proizvodnih površina brodogradilišta primjenom analize osjetljivosti. Odabrano optimalno projektno rješenje predstavlja podlogu za daljnje osnivanje proizvodnih tokova, te detaljnu razradu.

Predložena metodologija provjerena je kod projektiranja optimalnog rasporeda proizvodnih površina, a u okviru projekta tehnološke modernizacije postojećeg brodogradilišta. Sama procedura, metode, tehnike i alati na kojima se temelji predložena metodologija opisana je u daljnjem tekstu, a blok dijagram iste dan je na slici 4.1.



Slika 4.1. Blok dijagram predložene metodologije

4.1 FAZA 1 – Utvrđivanje pokazatelja odnosa bliskosti odabranih proizvodnih površina brodogradilišta metodom anketiranja

4.1.1 Uvod

Za primjenu predložene metodologije kod projektiranja rasporeda proizvodnih površina novog brodogradilišta potrebno je imati definiranu ciljanu tehnološku razinu rasporeda površina kao jedne grupe od tehnološke razine cjelokupnog brodogradilišta, a kako bi se utvrdile i uključile sve potrebne proizvodne površine. Za osnivanje novih brodogradilišta najčešće se nastoji postići najvišu tehnološku razinu rasporeda površina. Međutim, kod modernizacije postojećih brodogradilišta, prije svega je potrebno utvrditi stanje, odnosno trenutnu tehnološku razinu rasporeda površina kao temelj za daljnje unapređivanje i određivanje ciljane nove razine.

Postoji pet tehnoloških razina cjelokupnog brodogradilišta kako je prikazano u tablici 4.1.1.

Tablica 4.1.1. Tehnološke razine brodogradilišta, [111].

		Razdoblje	Opis
Tehnološka razina	1	1960-te	Dizalice male nosivosti, više navoza u funkciji, niska razina mehanizacije, bez uranjenog opremanja, ručni operativni sustavi
	2	1970-te	Manji broj navoza u funkciji, dok za gradnju, dizalice veće nosivosti, određena razina mehanizacije, korištenje računala za određene operativne sustave.
	3	1980-te	Dizalice velike nosivosti, određena razina zaštite okoliša, jedan dok ili površina za gradnju, viša razina mehanizacije, korištenje računala.
	4	1990-te	Jedan dok, viša razina zaštite okoliša, potpuno razvijeni operativni sustavi i značajno uranjeno opremanje.
	5	2000-te	Učinkovita automatizacija u većini procesa, integracija operativnih sustava (učinkovito korištenje CAD-a), učinkovito osiguranje kvalitete.

Za utvrđivanje navedene tehnološke razine cjelokupnog brodogradilišta potrebno je posebno analizirati sljedeće grupe u okviru istoga, [112]:

Grupa A – Predobrada i obrada čelika

Grupa B – Proizvodnja i sklapanje opreme

Grupa C – Ostale predmontažne aktivnosti

Grupa D – Gradnja i opremanje broda

Grupa E – Raspored površina i okoliš

Grupa F – Pogodnosti

Grupa G – Projektiranje, trasiranje, modeliranje i proizvodno inženjerstvo

Grupa H – Organizacija i operativni sustavi

Nadalje, u okviru svake od navedenih grupa brodogradilišta promatraju se pripadajuće podgrupe te se za svaku od njih utvrđuje tehnološka razina. Srednja vrijednost tehnoloških razina podgrupa predstavlja razinu grupe, dok se ukupna tehnološka razina brodogradilišta dobiva kao srednja vrijednost tehnoloških razina grupa.

U okviru ove faze za određivanje tehnološke razine rasporeda površina, relevantna je grupa E, odnosno njena podgrupa E1 koja razmatra raspored površina i proizvodne tokove brodogradilišta. Navedenu grupu pored spomenute podgrupe čine još i sljedeće navedene u tablici 4.1.2.

Tablica 4.1.2. Podjela Grupe E na pripadajuće podgrupe

- Grupa E – Podgrupe:	Raspored površina i okoliš
E1	Raspored površina i proizvodni tokovi
E2	Zaštita okoliša
E3	Rasvjeta i klimatizacija
E4	Buka i Ventilacija

Tehnološke razine relevantne podgrupe E1 opisuju se na način prikazan u tablici 4.1.3.

Tablica 4.1.3. Opis tehnoloških razina podgrupe E1.

		Opis
Tehnološka razina, Podgrupa E1: Raspored površina i proizvodni tokovi	1	Slaba veza između rasporeda površina i zahtijevanog proizvodnog toka. Značajno rukovanje materijalom suprotno osnovnom proizvodnom toku.
	2	Loše definiran raspored proizvodnih površina u određenim dijelovima brodogradilišta. Prisutno rukovanje materijalom suprotno osnovnom proizvodnom toku.
	3	Dobro definiran raspored proizvodnih površina koje prate osnovni proizvodni tok s odstupanjima uzrokovanim neizbježnim lokacijskim ograničenjima. Osnovni proizvodni tok uglavnom jednosmjernan.
	4	Reorganiziran raspored brodogradilišta bez značajnih lokacijskih ograničenja. Raspored površina projektiran na način da se postiže logičan i efikasan proizvodni tok s odgovarajućim proizvodnim i skladišnim površinama.
	5	Novoosnovano brodogradilište na lokaciji bez ikakvih ograničenja. Raspored proizvodnih površina projektiran na način da se u potpunosti postiže efikasnost proizvodnog toka. Potpuno odgovarajuće proizvodne i skladišne površine.

Kod projektiranja rasporeda proizvodnih površina novog brodogradilišta nastojati će se u okviru Grupe E, Podgrupe E1 postići tehnološka razina 5.


Kod projektiranja, odnosno modernizacije postojećeg brodogradilišta gotovo je nemoguće postići najvišu tehnološku razinu zbog raznih ograničenja. U tom slučaju nužno je utvrđivanje tehnoloških razina po svim grupama, a poglavito po grupama od A do E. Na taj način utvrditi će se stanje, odnosno dijelovi proizvodnog procesa te proizvodne površine koje nedostaju ili nisu na zadovoljavajućoj tehnološkoj razini. Temeljem utvrđenog stanja analizirati će se mogućnost unapređenja do najviše tehnološke razine ograničene postojećim i postavljenim zahtjevima.

Čest je slučaj da se kod izrade projekta modernizacije postojećih starijih brodogradilišta utvrdi da određene proizvodne površine ne postoje. U takvom slučaju potrebno je iste prepoznati, adekvatno ih dimenzionirati te uključiti u proceduru predložene metodologije kako bi se unapređenje proizvodnih tokova brodograđevnog procesa ostvarilo podizanje tehnološke razine postojećeg brodogradilišta.

Bilo da se radi o projektiranju novog ili modernizaciji postojećeg rasporeda proizvodnih površina u ovom su radu definirane one osnovne površine koje čine temelj proizvodnih tokova brodograđevnog procesa.

4.1.2 Odabir relevantnih proizvodnih površina brodogradilišta

Za prvu fazu predložene metodologije izvršen je izbor onih proizvodnih površina brodogradilišta za koje je dosadašnjim radom i istraživanjima utvrđeno da direktno participiraju u osnovnom proizvodnom toku brodograđevnog procesa. Posebno odabrane osnovne proizvodne površine brodogradilišta prikazane su numerirano na slici 4.1.1. na primjeru jednog modernog brodogradilišta najviše, pete tehnološke razine u okviru Grupe E, Podgrupe E1.



Slika 4.1.1. Prikaz brodogradilišta s označenim osnovnim proizvodnim površinama

Legenda:

1. Glavno skladište čeličnog materijala
2. Radionica za rezanje i oblikovanje limova
3. Radionica za rezanje i oblikovanje profila
4. Radionica za rezanje limova

5. Radionica za izradu panela
6. Radionica predmontaže
7. Radionica za zrnčenje i bojenje gotovih sekcija
8. Radionica za rezanje, oblikovanje i opremanje cijevi
9. Bravarska i limarska radionica
10. Opremna obala i ostale opremne radionice
11. Radionica za zrnčenje i bojenje opreme
12. Površina za odlaganje/ukrupnjivanje gotovih sekcija
13. Površina za odlaganje sekcija prije montaže na navozu
14. Navoz
15. More

Na istoj slici vidljivo je da površina pod brojem jedan predstavlja glavno skladište čeličnog materijala. Isto je locirano na takav način da je omogućena dobava materijala i morskim i kopnenim transportom što u određenim situacijama predstavlja bitnu prednost. U neposrednoj blizini glavnog skladišta smještene su proizvodne površine pod brojem dva i tri, odnosno radionice za rezanje i oblikovanje limova odnosno profila. Zatim, s rednim brojem četiri označena je radionica za rezanje limova koji nisu namijenjeni oblikovanju te je pripojena proizvodnoj površini označenoj s brojem pet, a koja predstavlja radionicu za izradu panela. Iz svih navedenih radnih površina, od one bod rednim brojem dva do one pod rednim brojem pet, osigurana je jednostavna komunikacija s proizvodnom površinom broj šest koja predstavlja radionicu predmontaže unutar koje se vrši izrada, odnosno sklapanje sekcija. Gotove sekcije odlaze na zrnčenje i bojenje u radionicu pod rednim brojem sedam. Zatim je osigurano dovoljno prostora za odlaganje te dodatno ukрупnjivanje i opremanje sekcija na radnim površinama 12 i 13. Iste se montiraju na radnoj površini broj 14, odnosno na navozu. Kada se osiguraju uvjeti za porinuće broda isti se predaje površini broj 15, odnosno moru. Brod se zatim vezuje uz opremnu obalu koju predstavlja površina broj deset gdje se vrši završno opremanje. Neposredno uz ovu površinu nalazi se i radionica za rezanje, oblikovanje i opremanje cijevi, tj. površina broj osam, te bravarska i limarska radionica, tj. površina broj devet. U njihovoj blizini nalazi se i radionica za zrnčenje i bojenje opreme pod rednim brojem 11.

Može se reći da prikazano brodogradilište na slici 4.1.1. predstavlja brodogradilište novijeg tipa čiji proizvodni tokovi prate suvremenu tehnologiju gradnje broda i to na najvišoj tehnološkoj razini.

Reorganizacija rasporeda ovih posebno odabranih proizvodnih površina na prostoru jednog brodogradilišta direktno mijenja osnovni proizvodni tok te na taj način utječe na performanse brodogradilišta. U tu svrhu, nužno je utvrđivanje pokazatelja odnosa bliskosti s pripadajućim težinskim faktorima kako bi se korištenjem odabrane metode za sistematsko planiranje rasporeda površina omogućila procjena u kojoj mjeri, pojedine varijante rasporeda proizvodnih površina, slijede saznanja o optimalnom osnovnom proizvodnom toku brodograđevnog procesa na višoj tehnološkoj razini.

Primjerice, temeljem osnovne tehnologičnosti, a kako je vidljivo i iz slike 4.1.1., bliskost između površina 14. i 15. je isključivo potrebna. Naime, površina 14. koja predstavlja navoz na kojemu se gradi brod nužno mora biti smještena uz površinu 15. koja predstavlja more. Ta bliskost je isključivo potrebna kako bi se omogućila predaja broda vodi. Međutim, iako postoji određen broj takvih situacija gdje se pokazatelj odnosa bliskosti između dviju proizvodnih površina može vrlo lako procijeniti, postoji i daleko veći broj situacija takvih da samo znanje i iskustvo eksperata može kvalitetno procijeniti bliskost između dvije odabrane proizvodne površine, a uzimajući u razmatranje čitav niz interakcija istih s ostalim dijelovima proizvodnog procesa gradnje broda kako bi se zadovoljila znanja o tehnologiji gradnje broda te ona o optimalnim proizvodnim tokovima brodograđevnog procesa. Stoga za utvrđivanje pokazatelja odnosa bliskosti i pripadajućih težinskih faktora u ovoj fazi je predloženo provođenje anketiranja značajnog broja brodograđevnih eksperata. Na taj način prikupiti će se dovoljna količina relevantnih podataka koji obrađeni na adekvatan način omogućuju utvrđivanje istih.

4.1.3 Utvrđivanje pokazatelja odnosa bliskosti i pripadajućih težinskih faktora

Pokazatelji odnosa bliskosti predstavljaju opisnu procjenu međuodnosa pojedinih proizvodnih površina sa stajališta optimalnih proizvodnih tokova te tehnološkičnosti gradnje općenito. Navedeni pokazatelji opisuju da li dvije razmatrane površine nužno moraju biti u blizini kako bi se uspostavio tehnološkičan slijed proizvodnje na najvišoj tehnološkoj razini. Pokazatelji odnosa bliskosti su u ovom radu opisani brojčanim kodovima, odnosno ocjenama od 0 do 5 te dodatno oznakama bliskosti, i to A, E, I, O, U i X, koje kao takve predstavljaju jedan od ulaznih podataka u okviru druge faze. Navedeni pokazatelji odnosa bliskosti prikazani su u tablici 4.1.4.

Primjerice, ako postoji isključiva potreba da dvije promatrane proizvodne površine budu u neposrednoj blizini, kao navoz i more tada će se njihov međuodnos označiti brojčanim kodom 5, te oznakom bliskosti A.

Tablica 4.1.4. Pokazatelji odnosa bliskosti

Kod	Bliskost	Oznaka bliskosti
5	Isključivo potrebna	A
4	Potrebna	E
3	Važna	I
2	Neznatno važna	O
1	Nevažna	U
0	Nepoželjna	X

Do utvrđivanja pokazatelja odnosa bliskosti, odnosno brojčanih kodova iz tablice 4.1.1., došlo se je metodom anketiranja značajnog broja relevantnih znanstvenih savjetnika i suradnika, te stručnjaka iz razmatranog polja brodogradnje koji su bili dostupni u velikim hrvatskim brodogradilištima i fakultetima brodogradnje. U tu svrhu pripremljen je posebno prilagođen anketni upitnik u okviru kojega se nalaze prethodno odabrane osnovne proizvodne površine koje se uspoređuju. Prikupljeni podaci uspoređivanja od strane eksperata s pripadajućim kodovima, kao i statistička obrada istih dana je u prilogu 1, u tablici P1.1.

U okviru istog anketnog upitnika predloženo je nekoliko grupa težinskih faktora, odnosno pondera za oznake bliskosti. Predloženi težinski faktori bili su elementi rastućeg niza, a razlikovali su se u brzini njegovog rasta. Isti su prikazani u tablici 4.1.5. a eksperti su vršili odabir jedne od ponuđenih grupa i to od grupe A do grupe F ili su predložili novu grupu G. Odabir težinskih faktora na temelju rezultata prikupljenih anketiranjem relevantnih eksperata također je prikazan u prilogu 1, i to u tablici P1.2.

Tablica 4.1.5. Predloženi težinski faktori pojedinih oznaka bliskosti.

Ozn. bliskosti	Bliskost	Grupa A	Grupa B	Grupa C	Grupa D	Grupa E	Grupa F	Grupa G
		Niz 1	Niz 2	Niz 3	Niz 4	Niz 5	Niz 6	Drugo
<i>A</i>	Isključivo potrebna	16	27	64	125	216	343	
<i>E</i>	Potrebna	4	9	16	25	36	49	
<i>I</i>	Važna	2	3	4	5	6	7	
<i>O</i>	Neznatno važna	1	1	1	1	1	1	
<i>U</i>	Nevažna	0	0	0	0	0	0	
<i>X</i>	Nepoželjna	-16	-27	-64	-125	-216	-343	

Na temelju prikupljenih podataka iz provedenog anketiranja relevantnih eksperata izvršeno je utvrđivanje težinskih faktora navedenih pokazatelja odnosa bliskosti uz pomoć slijedećeg izraza:

$$w_i = \frac{\sum_{k=1}^m \rho_{jk}}{m} \quad (1)$$

gdje je:

w_i - težinski faktor za i-tu bliskost,

ρ_{jk} - ocjena bliskosti za i-tu bliskost od k-tog eksperta,

m - broj ocjena/eksperata.

Utvrđenim težinskim faktorima pokazatelja odnosa bliskosti iz tablice 4.1.4. omogućeno je da se kroz iduću fazu, korištenjem metode za sistematsko planiranje rasporeda površina, međusobno ponderiraju odabrane proizvodne površine te izvrše procjene u kojoj mjeri njihov međusobni raspored unutar određene varijante zadovoljava saznanja o optimalnim proizvodnim tokovima.

Tablica odnosa (engl. *Relationship Chart, REL*) kojoj su utvrđeni pokazatelji odnosa bliskosti pripadajući elementi, predstavlja konvencionalni pristup za upravljanje neodređenostima. Ovakvim pristupom uzimaju se u razmatranje kvalitativni faktori i dinamičke situacije do čijih točnih podataka je nemoguće doći zbog raznih ograničenja.

4.1.4 Prijedlog za daljnje unapređenje faze 1

Kako je već spomenuto, postavke u vezi međusobnih odnosa pojedinih proizvodnih površina dobivene na ovaj način mogu potencijalno biti subjektivne, odnosno uzrokovane interpretacijama na različite načine od strane eksperata koji dolaze iz različitih sredina. Zbog toga se preporuča, za daljnje istraživanje, analiza i utvrđivanje parametara relevantnih za određivanje bliskosti proizvodnih površina brodogradilišta. Zatim, na temelju tih parametara preporuča se stvaranje baze podataka koju čine upravo podaci koje eksperti imaju kao formirano mišljenje. Nadalje, sa formiranom bazom podataka uz korištenje perspektivnih tehnika i alata temeljenih na Ekspertnim sustavima umanjiti će se potreba za anketiranjem eksperata. Na taj način će se dodatno unaprijediti predložena metodologija za potrebe ove faze.

4.2 FAZA 2 – Generiranje svih mogućih rješenja rasporeda razmatranih proizvodnih površina korištenjem SLP metode te odabir najizglednijih temeljem utvrđenih odnosa bliskosti

4.2.1 Uvod

Raspored površina brodogradilišta, odnosno pripadajući proizvodni tokovi imaju značajan utjecaj na performanse proizvodnog procesa [6]. Problem projektiranja rasporeda površina aktivno se istražuje već niz godina [29], međutim posebne metodologije namijenjene specifičnom proizvodnom procesu poput brodogradilišta ili nisu dostupne u literaturi, ili nisu adekvatne za rješavanje realnih problema.

Dostupna literatura koja tretira problem projektiranja rasporeda površina najčešće dijeli pristupe na algoritamske i proceduralne. Algoritamski pristupi najčešće pojednostavljaju projektne zahtjeve i ciljeve kako bi postigli objektivnu zamjensku funkciju čije je rješenje poznato [113]. Ovakvi pristupi obično uključuju isključivo kvantitativne ulazne parametre. Rješenja dobivena ovakvim pristupom mogu se lako evaluirati usporedbom vrijednosti njihovih objektivnih zamjenskih funkcija. Osnovni preduvjet za korištenje algoritamskih pristupa u projektiranju rasporeda površina jest poznavanje naprednih matematičkih metoda, tehnika i alata.

Proceduralni pristupi, međutim, primjereniji su za generiranje raznih varijanti mogućih rješenja jer mogu razmatrati pored kvantitativnih, i kvalitativne ciljeve u procesu projektiranja [13]. Projektiranje ovakvim pristupima vrši se u nekoliko sekvencijalnih koraka. Ulazni parametri kod ovakvih pristupa dobivaju se direktno od relevantnih eksperata te se brzo dolazi do većeg broja mogućih rješenja. Problem se javlja u posljednjem koraku kada je potrebno odabrati konačno rješenje koje će optimalno zadovoljiti višeciljne zahtjeve.

Nakon izvršene analize dosadašnjih istraživanja i dostignuća, te nakon utvrđivanja relevantnih parametara metodom anketiranja istaknutih eksperata u prvoj fazi, predloženo je korištenje metode sistematskog planiranja rasporeda površina, kao prikladno za drugu fazu ove metodologije.

4.2.2 Prikaz sistematskog planiranja rasporeda površina

Ova metoda se temelji na proceduralnom pristupu te je adekvatna za generiranje svih mogućih preliminarnih projektnih rješenja rasporeda proizvodnih površina brodogradilišta što je i željeni ishod u okvirima druge faze. Stoga u potpunosti zadovoljava potrebe i očekivanja kod projektiranja rasporeda površina, te se može uključiti u konfiguraciju predložene metodologije.

Dva su osnovna elementa na kojima se temelji problem vezan uz projektiranje metodom sistematskog planiranja rasporeda površina, [13]:

- *Proizvod* (ili roba ili usluga) koji je se mora proizvesti ili dati,
- *Količina* (ili volumen), koliko se mora proizvoditi.

Direktno ili indirektno, ova dva elementa ističu sve ostale značajke ili zahtjeve u projektiranju rasporeda površina. Stoga, činjenice, procjene, te ostale informacije vezane uz ta dva elementa su neophodne.

Pod *proizvodom* se podrazumijevaju dobra koje proizvodi poduzeće, odnosno razmatrana površina, kao i ulazni materijal, odnosno sirovina za obradu ili oprema za ugradbu.

Pod *količinom* se podrazumijeva kvantiteta proizvedenih, odnosno isporučenih dobara ili usluga. Količina može biti izražena u broju komada, masi, volumenu ili vrijednosti proizvedenog ili prodanog.

Nakon što se priskrbe svi ulazni parametri i informacije o *proizvodu* i *količini*, pristupa se *usmjeravanju* procesa, odnosno definiranju kako će se proizvod izrađivati. Pod navedenim *usmjeravanjem* se, pored samoga procesa podrazumijeva pripadajuća oprema, operacije te njihov redoslijed izvršavanja.

Potporu operacijama u okviru proizvodnih aktivnosti daje velik broj službi *podrške*. Pod *podrškom* se podrazumijevaju usluge, pomoćni uređaji, te pripadajuće aktivnosti ili funkcije koje moraju biti osigurane na razmatranoj površini kako bi se proizvodni proces efikasno odvijao. Stoga *podrška* uključuje održavanje, popravak strojeva, alatnicu, sanitarne čvorove i svlačionice, menzu, prvu pomoć, osnovne radionice, razni promet unutar proizvodnog procesa, skladišta i sl. Kada se uzmu u obzir sve službe *podrške* zajedno, često one zauzimaju više prostora od samih proizvodnih pogona. Stoga odgovarajuća pozornost mora biti usmjerena i na njih.

Sljedeći osnovni podatak za rješavanje problema projektiranja rasporeda površina jest obračun vremena. Tu se podrazumijeva kada, koliko dugo, koliko često i koliko skoro će se odvijati proizvodni proces. Dakle *vrijeme* uključuje kada će se proizvod izrađivati ili za kada je planirano da razmatrani prostor bude operabilan. Zahtijevano vrijeme proizvodnih operacija određuje broj i tip potrebne proizvodne opreme (strojeva), što nadalje definira potrebne površine, ljudske resurse itd.

Sama procedura, kako je shematski prikazano na slici 4.2.1., započinje prvim korakom, odnosno *PQRST* analizom koja obuhvaća sakupljanje podataka o:

- proizvodu, P (engl. *product*);
- količini, Q (engl. *quantity*);
- tokovima, R (engl. *routeing*);
- podršci, S (engl. *support*);
- vremenu, T (engl. *time*);

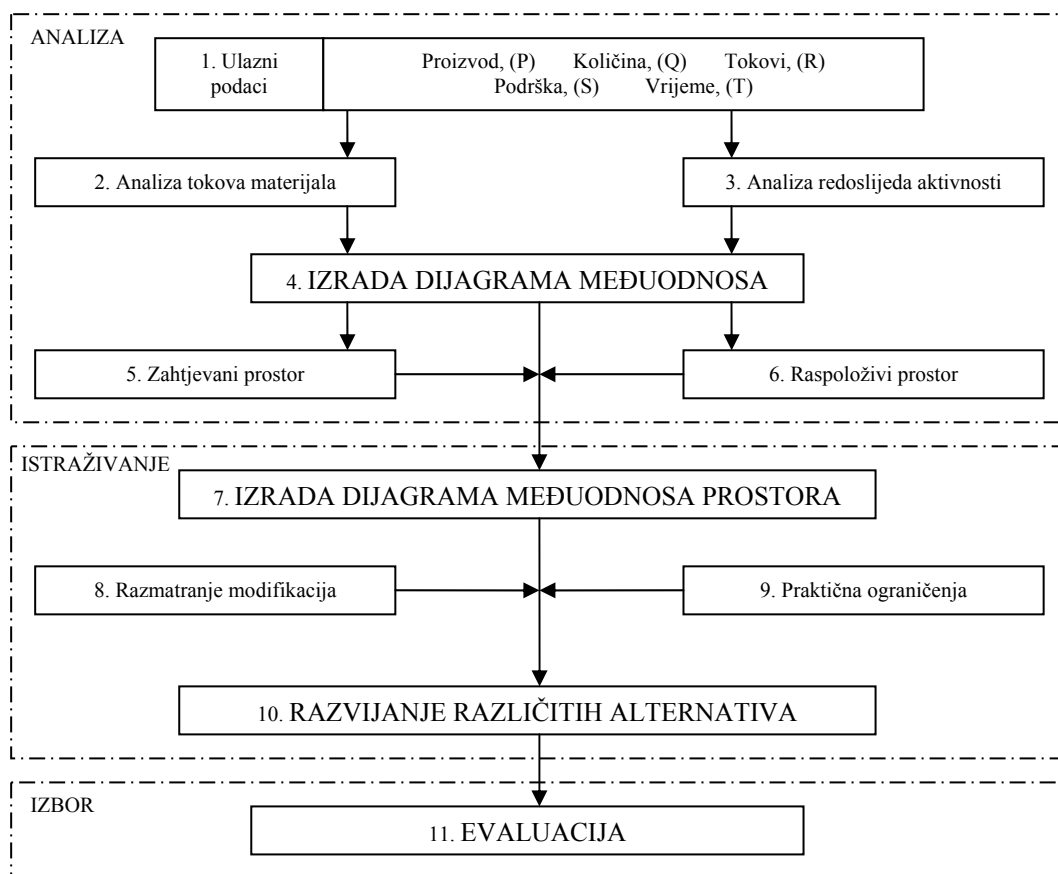
koji se obrađuju na način da se zadovolji forma ulaznih parametara.

U drugom koraku vrši se analiza proizvodnih tokova. Tu se svi podaci o proizvodnim tokovima, unutar promatranog brodograđevnog proizvodnog procesa, unašaju u posebnu matricu koja ih povezuje sa pripadajućim površinama brodogradilišta.

Treći korak predstavlja analizu redoslijeda aktivnosti kojom se kvalitativno određuju međuodnosi pojedinih odjela brodogradilišta.

U četvrtom koraku vrši se izrada dijagrama međuodnosa pomoću kojega se vrši nasumično pozicioniranje pojedinih odjela brodogradilišta, ali vodeći računa da oni odjeli koji imaju jaku međusobnu vezu budu smješteni u neposrednoj blizini.

U petom i šestom koraku određuje se veličina potrebnog prostora za pojedine odjele. U dijagramu međuodnosa pojedinih prostora, sedmi korak, dodaju se informacije o dimenzijama odjela u dijagram iz četvrtog koraka. Dodatno se u osmom i devetom koraku razmatraju specifični zahtjevi i ograničenja prije početka razvijanja različitih alternativnih rješenja koje se vrše u desetom koraku. U jedanaestom koraku vrši se evaluacija razvijenih alternativnih rješenja te odabir izglednih povoljnih rješenja.



Slika 4.2.1. SLP procedura, [13].

Međutim, kako bi se odabrana metoda što efikasnije uključila u predloženu metodologiju ona je prilagođena na način da su odabrani samo određeni koraci. Dosadašnjim istraživanjem utvrđeno je da neki koraci trebaju biti izuzeti jer ograničavaju metodu, a mogu biti efikasnije i kvalitetnije izvršeni u okviru slijedeće faze korištenjem metoda za višeciljne analize. Ovakvo pojednostavljeno sistematsko planiranje rasporeda površina [114], pogodno je za korištenje u fazama generiranja preliminarnih rješenja, što je i osnovna karakteristika i svrha razmatrane faze.

Općenito, svaki raspored brodogradilišta uključuje:

- 1) Odnose bliskosti pojedinih površina unutar prostora namijenjenih pojedinim aktivnostima,
- 2) Površine i oblik pojedinog prostora,
- 3) Razmještaj navedenoga u okvirima brodogradilišta.

Vodeći računa upravo o uključenim elementima, u drugoj fazi se proceduralno dolazi do postavljenog cilja korištenjem prilagođene metode sistematskog planiranja rasporeda

površina. Za brže generiranje rezultata preporuča se korištenje specijaliziranog računalskog programa [115].

Cilj korištenja ove metode jest odabir najizglednijih rasporeda proizvodnih površina analizom i procjenom svih mogućih kombinacija zadanih proizvodnih površina u definirani prostor brodogradilišta. Takvih kombinacija može biti mnogo, primjerice za prostor koji razmatra 20 proizvodnih površina broj mogućih kombinacija je $2,4 \cdot 10^{18}$. Budući da postoje radne površine koje nužno moraju biti u blizini, te postoje i one za koje nije poželjno da su u blizini, a što proizlazi iz postavljenih zahtjeva, potrebno je izdvojiti samo kombinacije istih koje se mogu uzeti u razmatranje kao najizglednijih rješenja.

Na taj način moguće je sve kombinacije zadanih radnih površina unutar definiranog prostora, kao alternative rasporeda površina, međusobno usporediti. Ono se u okviru odabrane metode vrši na temelju tzv. *SLP* ocjene rasporeda površina (engl. *SLP score*) dobivene pomoću kriterija bliskosti za koji vrijedi slijedeći izraz:

$$s = \sum_{i=1}^{n_p} w_i \cdot Y_i \quad (2)$$

gdje je,

- Y_i - broj bliskosti u i-toj klasi,
- w_i - težinski faktor za i-tu bliskost,
- s - ocjena rasporeda površina,
- n_p - broj radnih površina.

Veća vrijednost *SLP* ocjene rasporeda površina u okviru promatrane varijante, znači i veće približenje optimalnim tokovima brodograđevnog procesa. Najveća moguća vrijednost normalizirane ocjene rasporeda površina dobivene temeljem kriterija bliskosti je jedan.

Od svih generiranih varijanti rasporeda površina, jedna će zasigurno biti najbolja sa stajališta *SLP* ocjene, međutim to nije nužno i optimalno projektno rješenje sa stajališta cijelog brodogradilišta. Naime, pored zahtjeva za optimalnim proizvodnim tokovima, u obzir moraju biti uzeti i ostali postojeći te postavljeni zahtjevi koji su također vrlo značajni kod projektiranja rasporeda površina. Dakle, zahtjevi kao što su ograničena veličina investicija potrebnih da se realizira predloženo projektno rješenje, zatim postojeća infrastruktura koja se ne može mijenjati ili micati, nadalje nužnost neometanog odvijanja tekuće proizvodnje, i sl., predstavljaju realne zahtjeve ali koje nije moguće uključiti u okviru ove faze.

Iz tog razloga, u okviru ove faze, predlaže se odabir 20 najizglednijih varijanti projektnog rješenja, dobivenih na temelju *SLP* ocijene, jer se smatra da se upravo unutar takvog uzorka nalazi ono rješenje koje će optimalno zadovoljiti i ostale kriterije.

4.2.3 Računalski program za sistematsko planiranje rasporeda površina

Budući je, u okviru ove faze, potrebno analizirati velik broj mogućih rasporeda proizvodnih površina, preporuča se korištenje specijaliziranog računalskog programa. Jedan takav program, primjenjiv te preporučen za potrebe u okviru ove faze, je *Block Plan for Windows 1.4* [115]. Ovaj program namijenjen je rješavanju raznih problema projektiranja rasporeda površina upravo primjenom pojednostavljene *SLP* metode. Pomoću njega omogućeno je brzo generiranje i procjena svih varijanti rasporeda površina temeljem odnosa bliskosti utvrđenih u prvoj fazi ove metodologije. Prikaz uvodnih radnih sučelja ovog programa dani su na sljedećim slikama.

The screenshot shows the BLOCPLAN software window. It contains a table with 15 rows, each representing a department. The columns are labeled 'Number', 'Department', and 'Area'. Below the table, there are three red labels: '1. stupac', '2. stupac', and '3. stupac' corresponding to the columns. At the bottom, there are input fields for 'Average Area' (2804,3), 'Std. Dev. Area' (2952,2), and 'Total Area' (42064). There are also buttons for 'Continue', 'Print', and 'Back'.

Number	Department	Area
1	SKL	3520
2	ROL	1479
3	ROP	1360
4	RRL	2232
5	PAN	4480
6	RPM	3520
7	ZIB	540
8	RIC	1330
9	BIL	915
10	MOT	334
11	ZBO	300
12	OD1	784
13	OD2	1920
14	NAV	9350
15	SEA	10000

1. stupac 2. stupac 3. stupac

Average Area: 2804,3 Std. Dev. Area: 2952,2 Total Area: 42064

Continue Print Back

Slika 4.2.2. Osnovni podaci o razmatranim proizvodnim površinama

Legenda:

SKL	- Glavno skladište čeličnog materijala
ROL	- Radionica za rezanje i oblikovanje limova
ROP	- Radionica za rezanje i oblikovanje profila
RRL	- Radionica za rezanje limova
PAN	- Radionica za izradu panela + mala predmontaža
RPM	- Radionica predmontaže
ZIB	- Radionica za zrnčenje i bojenje gotovih sekcija
RIC	- Radionica za rezanje i oblikovanje cijevi
BIL	- Radionica s odjeljenjima za bravare i limare
MOT	- Oprema obala i ostale opremne radionice
ZBO	- Radionica za zrnčenje i bojenje opreme
OD1	- Površina za odlaganje/ukrupnjivanje sekcija
OD2	- Površina za odlaganje gotovih sekcija
NAV	- Površine za gradnju i predaju broda vodi
SEA	- Površina mora na prostoru brodogradilišta

Radno sučelje na slici 4.2.2. sastoji se od tri stupca u koje se unose osnovni ulazni podaci vezani za odabrane proizvodne površine. U prvi stupac upisuje se redni broj, u drugi stupac upisuju se odabrane relevantne proizvodne površine i to skraćenim nazivom (vidi legendu), dok se u treći stupac unose podaci o pripadajućoj površini u kvadratnim metrima. Za određivanje površine u kvadratnim metrima pojedinih proizvodnih površina potrebno je znati zahtijevanu produktivnost brodogradilišta na osnovi koje se vrši dimenzioniranje istih. Ukupnu površinu, te ostale podatke program izračunava automatizirano.

Nadalje, radno sučelje na slici 4.2.3. predstavlja sljedeći korak u ispunjavanju ulaznih podataka, odnosno matricu odnosa bliskosti odabranih proizvodnih površina.

U prvom stupcu nabrojane su odabrane proizvodne površine s pripadajućim rednim brojevima, dok su u prvom retku nabrojeni samo redni brojevi koji predstavljaju pojedine proizvodne površine. U ostatku matrice isti su međusobno povezani na način da se mogu u parovima uspoređivati (svaka sa svakom). Odabrane proizvodne površine međusobno se uspoređuju na temelju odnosa bliskosti utvrđenih u prethodnoj fazi.

RELFORM

RELATIONSHIP CHART

		2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	SKL	A	A	A	O	O	U	E	O	O	U	U	U	I	
2	ROL		I	I	I	E	U	U	U	U	O	U	O	U	
3	ROP			I	E	E	U	U	O	U	O	U	U	U	
4	RRL				A	E	U	U	O	U	O	U	O	U	
5	PAN					A	I	U	O	U	I	O	O	U	
6	RPM						A	I	I	O	E	E	I	O	
7	ZIB							U	U	O	E	E	E	E	U
8	RIC								I	E	E	I	I	I	
9	BIL								E	E	I	O	I	O	
10	MOT									I	I	O	I	E	
11	ZBO										I	I	I	U	
12	OD1											I	A	O	
13	OD2												E	O	
14	NAV													A	
15	SEA														

1. stupac


1. radak

A = Absolutely Essential I = Important U = Unimportant
 E = Essential O = Ordinary X = Undesireable

Continue Print

Slika 4.2.3. Matrica odnosa bliskosti ispunjena podacima proizašlim iz prve faze

Ovaj program zatim vrši raspoređivanje odabranih proizvodnih površina na sve moguće načine unutar zadanih okvira, automatizirano izračunava *SLP* ocjenu rasporeda površina te pojednostavljeno prikazuje raspored istih na izlaznom sučelju. Prikaz takvog, izlaznog radnog sučelja dan je na slici 4.2.4.



Slika 4.2.4. Izlazno radno sučelje s pojednostavljenim prikazom rasporeda površina

Osnovna ulazna i izlazna radna sučelja ovog programa korištena na primjeru primjene predložene metodologije na projektiranju rasporeda proizvodnih površina postojećeg brodogradilišta prikazana su u okviru petog poglavlja, odnosno u pripadajućem prilogu 2.

Block Plan for Windows 1.4 razvijen je i prilagođen osobnim računalima na University of Houston - Cullen College of Engineering, Department of Industrial Engineering. Autori su prof. dr. sc. Charles E. Donaghey, dr. sc. Christopher A. Chung, assist. Haiyan Kong i assist. Vanina F. Pire.

Program je ustupljen autoru ovog rada te Katedri za tehnologiju i organizaciju brodogradnje pri Zavodu za brodogradnju i inženjerstvo morske tehnologije, Tehničkog fakulteta, Sveučilišta u Rijeci, po posebnim uvjetima od strane cijenjenog prof. dr. sc. Charles E. Donaghey-a.

4.3 FAZA 3 – Hijerarhijsko modeliranje AHP metodom za projektiranje optimalnog rasporeda razmatranih proizvodnih površina brodogradilišta

4.3.1 Uvod

Kako je prethodno utvrđeno, potrebno je iznaći metodu za rješavanje problema koji nadilaze mogućnosti *SLP* metode. Stoga se za projektiranje optimalnog rješenja rasporeda površina predlaže hijerarhijsko modeliranje, koje predstavlja opću teoriju mjerenja, a koja se koristi za izvođenje mjernog odnosa iz diskretnih i kontinuiranih sučeljenih usporedbi. Ove usporedbe mogu biti preuzete iz aktualnih mjerenja ili temeljnih mjera koje odražavaju relativnu snagu preferenci i uvjerljivosti.

Za treću fazu u ovdje predloženoj metodologiji, tj. za odabir projektnog rješenja koje će optimalno zadovoljiti postavljene kriterije, predlaže se analitički hijerarhijski proces, tj. *AHP* metoda. Ista predstavlja jednu od metoda znanstvene analize scenarija i donošenja odluka konzistentnim vrednovanjem hijerarhijske strukture koju čine ciljevi, kriteriji, podkriteriji te alternative.

Alternative, kao najizglednije varijante rješenja, se preuzimaju iz prethodne faze. Međutim, za vrjednovanje istih, kod projektiranja rasporeda proizvodnih površina brodogradilišta, može postojati čitav niz kriterija i podkriterija. Kriteriji i podkriteriji uključuju se u izradu hijerarhijskog modela te se na osnovu njih, među alternativama, traži optimalno rješenje kao cilj.

Nadalje, navedeni kriteriji i podkriteriji nemaju jednake prioritete, tj. nisu isti po važnosti.

4.3.2 Utvrđivanje potencijalnih parametara za hijerarhijsko rangiranje

U okviru ove faze, kod formiranja hijerarhijskog modela, preporuča se analiza i definiranje relevantnih kriterija i podkriterija na temelju grupa i podgrupa tehnološke raščlambe navedene u tablici 4.3.1. Uz popis grupa i podgrupa relevantnih za formiranje kriterija i podkriterija pri izradi hijerarhijskog modela te relevantnih za podizanje tehnološke razine brodogradilišta, u istoj su tablici dani podaci o tehnološkim razinama dobiveni metodom uspoređivanja s drugim konkurentnim brodogradilištima (engl.

Banchmarking method), [111]. Na temelju tih ocjena može se utvrditi koje su ciljane tehnološke razine te prioriteti pri izradi hijerarhijskog modela.

Tablica 4.3.1. Tehnološka raščlamba na grupe i podgrupe relevantne za procjenu tehnološke razine brodogradilišta i procjenu kriterija.

Grupa	Naziv	Podgrupa	Tehnološka razina (1 do 5)					Ukupno
			Brodogradilište 1	Brodogradilište 2	Brodogradilište 3	Brodogradilište 4	Brodogradilište 5	
A	Predobrada i obrada čelika							3,7
		Predobrada limova	4	5	4	3	3	3,8
		Predobrada profila	4	5	4	3	3	3,8
		Rezanje limova	4	5	4	4	5	4,4
		Rezanje profila	4	4	4	4	5	4,2
		Oblikovanje limova i profila	4	4	4	4	3	3,8
		Linija za izradu panela	3	4	4	4	5	4,0
		Predmontaža	4	4	3	4	3	3,6
		Mont. zakrivljenih sekc. i pregrada	4	4	3	4	3	3,6
		Montaža VTS na navozu	3	4	3	3	3	3,2
		Montaža nadgrađa na navozu	3	4	3	3	3	3,2
		Opremanje	3	3	3	3	3	3,0
B	Proizvodnja i sklapanje opreme							3,4
		Obrada i oblikovanje cijevi	4	4	4	4	3	3,8
		Strojogradnja	4	3	3	3	3	3,2
		Limarski radovi	3	3	3	3	3	3,0
		Stolarski radovi	3	4	5	4	3	3,8
		Električarski radovi	4	4	2	3	4	3,4
		Montaža opreme	4	3	2	3	4	3,2
		Održavanje	4	3	3	4	4	3,6
		Skladištenje opreme	3	3	4	3	2	3,0
		Skladištenje strojeva	4	3	3	3	3	3,2
C	Ostale predmontažne aktivnosti							3,4
		Izrada sklopova i modula	4	4	4	4	3	3,8
		Uranjeno opremanje	4	4	4	4	3	3,8
		Sklapanje blokova	3	3	3	3	3	3,0
		Skladištenje blokova	3	3	3	3	2	2,8

Nastavak tablice 4.3.1.

D	Gradnja i opremanje broda na navozu						3,5
	Gradnja broda	3	3	3	3	3	3,0
	Sklapanje i izgladivanje	4	3	4	4	3	3,6
	Zavarivanje	4	4	4	4	3	3,8
	Oskeljenje	4	3	3	4	2	2,8
	Cjevarski radovi	4	3	4	4	3	3,6
	Radovi u strojarnici	4	4	4	4	3	3,8
	Limarski radovi	3	3	3	3	3	3,0
	Električarski radovi	4	4	3	3	3	3,2
	Zrnčenje i bojenje	3	4	4	5	3	3,8
	Ispitivanje i puštanje u rad	5	5	4	4	4	4,4
	Aktivnosti nakon porinuća	4	3	4	3	3	3,4
E	Raspored površina i okoliš						3,6
	Raspored površina i proizv. tokovi	4	4	4	4	3	3,8
	Zaštita okoliša	4	4	3	4	2	3,4
	Rasvjeta i klimatizacija	3	4	3	4	3	3,4
	Buka i ventilacija	3	4	3	4	4	3,6
F	Pogodnosti						3,9
	Marendariji	4	3	3	4	5	3,8
	Svlačionice, tuševi, WC	4	4	4	5	3	4,0
	Ostale pogodnosti	4	4	4	4	3	3,8
G	Projektiranje, trasiranje, modeliranje i proizvodno inženjerstvo						3,9
	Projektiranje broda	4	4	4	4	4	4,0
	Izrada tehnoloških nacrti	4	4	4	4	4	4,0
	Označavanje elemenata	3	5	4	4	4	4,0
	Projektiranje za proizvodnju	4	4	4	4	3	3,8
	Dimenzijska kontrola	4	4	4	4	3	3,8
	<i>Nesting</i>	4	4	4	4	4	4,0
H	Organizacija i operativni sustavi						3,9
	Organizacija rada	5	4	3	4	3	3,8
	Ugovaranje i planiranje	3	3	4	4	3	3,6
	Planiranje proizvodnje	4	5	4	4	3	4,0
	Planiranje opremanja	4	4	4	4	3	3,8
	Nadzor	4	4	4	4	4	4,0
	Učinkovitost	4	4	4	4	3	3,8
	Primjena računala	4	4	4	4	4	4,0
	Nabava	4	4	4	4	3	3,8

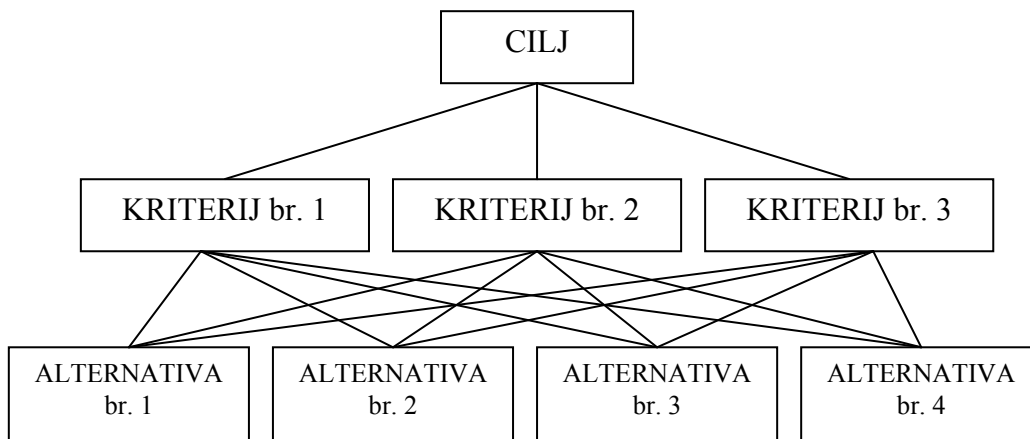
Primjerice kod primjene ove metodologije za modernizaciju postojećeg brodogradilišta, nakon što se utvrdi zatečena tehnološka razina, moći će se analizirati koje proizvodne površine bitno zaostaju (ako uopće postoje), te one koje su na zadovoljavajućoj tehnološkoj razini u usporedbi s danom tablicom. Na taj način utvrđene proizvodne površine moći će se adekvatno dimenzionirati i ponderirati. Optimalni raspored istih u okvirima brodogradilišta predstavlja cilj hijerarhijskog modela.

4.3.3 Metodološki temelji analitičkog hijerarhijskog procesa

Analitički hijerarhijski proces se svrstava u sisteme podrške pri donošenju odluke (*engl. Decision Support System, DSS*). Sastoji se od konkretnog matematičkog modela te je primjenjiv za opće namjene gdje je potrebna podrška pri donošenju odluka. Intenzivno se koristi za potrebe odlučivanja u menadžmentu te kod upravljanja, alokacije i distribucije. Idejnu i matematičku postavku ove metode dao je Thomas L. Saaty [12].

Analitički hijerarhijski proces spada u kategoriju metoda za meku optimizaciju (*engl. soft optimization*). U osnovi se radi o specifičnom alatu za formiranje i analizu hijerarhije odlučivanja. Ono prije svega omogućava interaktivno kreiranje hijerarhije problema kao pripremu scenarija odlučivanja, zatim vrjednovanje u parovima pojedinih elemenata hijerarhijske strukture tj. ciljeva, kriterija, i alternativa od vrha prema dnu (*engl. top-down*). Završno se vrši sinteza svih vrednovanja te se po definiranom matematičkom modelu određuju težinski koeficijenti svih elemenata hijerarhijske strukture. Zbroj težinskih koeficijenata elemenata na svakoj hijerarhijskoj razini jednak je jedinici.

Metodološki promatrano, analitički hijerarhijski proces je višekriterijska metoda koja se temelji na raspodijeli složenog problema u hijerarhijsku strukturu. Na najvišoj razini strukture nalazi se cilj, dok su kriteriji, pod-kriteriji i alternative redom na nižim hijerarhijskim razinama, slika 4.3.1.

Slika 4.3.1. Hijerarhijska struktura *AHP* metode

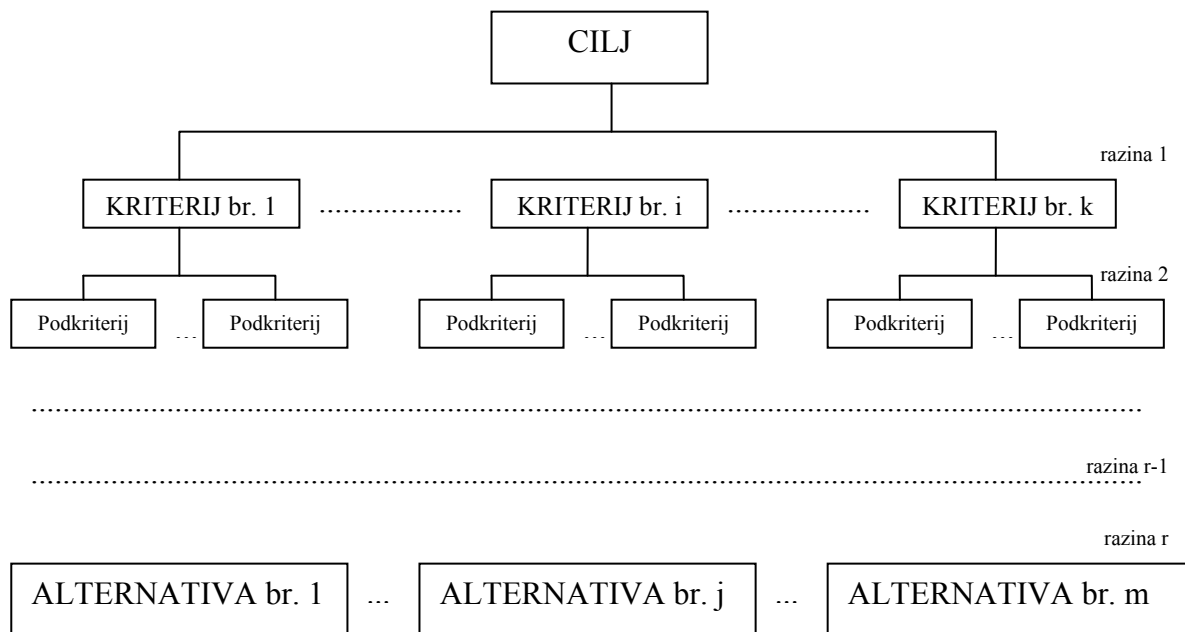
Analitički hijerarhijski proces je fleksibilan jer omogućava da se, kod složenih problema sačinjenih od velikog broja kriterija i alternativa, relativno lako dođe do relacije između utjecajnih faktora, prepozna njihov eksplicitni ili relativni utjecaj i značaj u realnim situacijama i odredi dominantnost jednog faktora u odnosu na drugi. Metoda naime, anticipira činjenicu da se i najsloženiji problem može podijeliti na hijerarhijsku strukturu i to tako da su u daljnju analizu uključeni i kvalitativni aspekti problema. Metoda međusobno povezuje sve dijelove hijerarhijske strukture na način da je moguće kod promjene jednog faktora vidjeti njegov utjecaj na ostale.

Metoda se do danas primjenjivala u raznim područjima strateškog menadžmenta gdje odluke imaju dalekosežan značaj i stoga donosioci odluka teže odabiru kvalitetne i pouzdane metode u fazi razmatranja alternativa i utvrđivanja njihovih utjecaja na postavljene ciljeve.

4.3.4 Matematički temelji analitičkog hijerarhijskog procesa

Hijerarhijski strukturiran model odlučivanja sastoji se od cilja, kriterija, pod-kriterija te alternativa, slika 4.3.2. Cilj se nalazi na najvišoj razini hijerarhijske strukture, te se on s nijednim drugim elementom ne uspoređuje. Na prvoj razini se nalazi k kriterija koji se u parovima, svako sa svakim, uspoređuju u odnosu na neposredno nadređeni element na višoj razini, a to je cilj. Potrebno je ukupno $k \cdot (k - 1) / 2$ uspoređivanja. Isti postupak se ponavlja u sljedećoj hijerarhijskoj razini, pa tako sve prema niže dok se na posljednjoj r -toj

razini ne izvrše uspoređivanja svih alternativa u odnosu na nadređene pod-kriterije na pretposljednjoj $r - 1$ razini.



Slika 4.3.2. Opći hijerarhijski model AHP metode

Metoda se zasniva na sljedećim aksiomima:

- Aksiom recipročnosti. Ako je element A n puta značajniji od elementa B, tada je element B $1/n$ puta značajniji od elementa A.
- Aksiom homogenosti. Uspoređivanje ima smisla samo ako su elementi usporedivi.
- Aksiom zavisnosti. Uspoređivanje na nižoj razini zavisno je od elementa više razine.
- Aksiom očekivanja. Svaka promjena u strukturi hijerarhije zahtjeva ponovno računanje prioriteta u novoj hijerarhiji.

Svako uspoređivanje dva elementa hijerarhije (modela) vrši se korištenjem *Saaty*-jeve skale vrednovanja, tablica 4.3.2.

Tablica 4.3.2. *Saaty*-jeva skala vrednovanja

Značaj	Definicija	Opis
1	Istog značaja	Dva kriterija ili alternative jednako doprinose cilju
3	Slaba dominantnost	Na temelju iskustva i procjena daje se umjerena prednost jednom kriteriju ili alternativu u odnosu na drugi
5	Jaka dominantnost	Na temelju iskustva i procjena strogo se favorizira jedan kriterij ili alternativa u odnosu na drugi
7	Dokazana dominantnost	Jedan kriterij ili alternativa izrazito se favorizira u odnosu na drugi; njegova dominacija dokazuje se u praksi
9	Apsolutna dominantnost	Dokazi na temelju kojih se favorizira jedan kriterij ili alternativa u odnosu na drugi potvrđeni su s najvećom uvjerljivošću
2,4,6,8	Međuvrijednosti	Potreban kompromis ili daljnja podjela

$$S = \left\{ \frac{1}{9}, \frac{1}{8}, \frac{1}{7}, \frac{1}{6}, \frac{1}{5}, \frac{1}{4}, \frac{1}{3}, \frac{1}{2}, 1, 2, 3, 4, 5, 6, 7, 8, 9 \right\} \quad (3)$$

U izrazu (3), S predstavlja skup mogućih vrijednosti dodijeljivih međusobnom odnosu dvaju promatranih elementa unutar hijerarhijske strukture.

Rezultati uspoređivanja elemenata na datoj razini hijerarhijske strukture svrstavaju se u odgovarajuće matrice na sljedeći način:

Ako se međusobno uspoređuje n elemenata u odnosu na odgovarajući element na neposredno višoj razini hijerarhijske strukture, tada se pri uspoređivanju i -tog elementa u odnosu na j -ti element, pomoću *Saaty*-jeve skale određuje numerički koeficijent a_{ij} te se svrstava na odgovarajuću poziciju u matrici A :

$$A = \begin{bmatrix} a_{11} & a_{12} & \cdot & \cdot & a_{1n} \\ a_{21} & a_{22} & \cdot & \cdot & a_{2n} \\ \cdot & \cdot & & & \cdot \\ \cdot & \cdot & & & \cdot \\ a_{n1} & a_{n2} & \cdot & \cdot & a_{nn} \end{bmatrix} \quad (4)$$

Recipročna vrijednost rezultata uspoređivanja smješta se na poziciji a_{ji} kako bi se očuvala konzistentnost rasuđivanja. Primjerice, ako je element 1 neznatno favoriziran u odnosu na element 2, na mjestu a_{12} matrice A biti će broj 3 iz *Saaty*-jeve skale, a na mjestu a_{21} biti će njegova recipročna vrijednost, odnosno $1/3$.

Za slučaj konzistentnih procjena, matrica A , u koju se svrstavaju rezultati uspoređivanja njihovih omjera, a koji se označavaju s $a_{ij} = w_i/w_j$, bila bi ista kao matrica X :

$$X = \begin{bmatrix} w_1/w_1 & w_1/w_2 & \cdot & \cdot & w_1/w_n \\ w_2/w_1 & w_2/w_2 & \cdot & \cdot & w_2/w_n \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ w_n/w_1 & w_n/w_2 & \cdot & \cdot & w_n/w_n \end{bmatrix} \quad (5)$$

gdje w_i predstavlja relevantni težinski koeficijent i -tog elementa.

Da bi se iz matrice A ekstrahirale vrijednosti vektora težinskih koeficijenata $w^T = \{w_1, w_2, \dots, w_n\}$ koje bi bile bliske aproksimacije odgovarajućih elemenata matrice X , autor metode je predložio da se za matricu A najprije odredi njena maksimalna svojstvena vrijednost, λ_{\max} . Odgovarajući vektor svojstvenih vrijednosti matrice može se zatim uzeti kao vektor približnih vrijednosti težinskih koeficijenata, w^T , jer vrijedi:

$$\begin{bmatrix} w_1/w_1 & w_1/w_2 & \cdot & \cdot & w_1/w_n \\ w_2/w_1 & w_2/w_2 & \cdot & \cdot & w_2/w_n \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ w_n/w_1 & w_n/w_2 & \cdot & \cdot & w_n/w_n \end{bmatrix} \cdot \begin{bmatrix} w_1 \\ w_2 \\ \cdot \\ \cdot \\ w_n \end{bmatrix} = n \cdot \begin{bmatrix} w_1 \\ w_2 \\ \cdot \\ \cdot \\ w_n \end{bmatrix} \quad (6)$$

Vektor w može se dobiti rješavanjem sistema homogenih linearnih jednadžbi:

$$A \cdot w = n \cdot w \quad \text{ili} \quad (A - nI) \cdot w = 0 \quad (7)$$

Sistem ima netrivialno rješenje ako i samo ako je n svojstvena vrijednost matrice A , tj. ako je determinanta matrice $(A - nI)$ jednaka nuli, gdje I označava jediničnu matricu.

Sada matrica X ima rang 1, pošto je svaki red matrice produkt konstante i prvog reda matrice. Zbog toga su sve svojstvene vrijednosti, osim jedne, jednake nuli. Suma svojstvenih vrijednosti matrice jednaka je tragu matrice. U ovom slučaju trag matrice X jednak je n . Prema tome, n je svojstvena vrijednost matrice A i sistem jednadžbi (5) ima

netrivijalno rješenje. Rješenje se sastoji od pozitivnih elemenata u vektoru rješenja i ono je jedinstveno u granicama date multiplikativne konstante (teorem *Perron – Frobenius*) [115]. Da bi se postiglo da w bude jedinstveno, njegovi elementi se normaliziraju tako što se podijele sa njihovom sumom.

Nadalje, za određivanje vektora težinskih koeficijenata w , preporuča se tehnika koja uključuje sumiranje redova matrice rezultata uspoređivanja i normalizaciju dobivenih suma, jer je:

$$\sum_{j=1}^n \frac{w_i}{w_j} = w_i \left(\sum_{j=1}^n \frac{1}{w_j} \right) \quad i = 1, \dots, n \text{ (po redovima)}. \quad (8)$$

Vektor težinskih koeficijenata w može se dobiti i na način da se recipročne vrijednosti suma stupaca normaliziraju:

$$\sum_{i=1}^n \frac{w_i}{w_j} = \frac{1}{w_j} \left(\sum_{i=1}^n w_i \right) \quad j = 1, \dots, n \text{ (po stupcima)}. \quad (9)$$

Kada se neki od navedenih načina odredi, vektor težinskih koeficijenata w se zatim množi sa težinskim koeficijentom elementa sa više razine koji je korišten kao kriterij pri uspoređivanju.

Procedura se ponavlja idući prema nižim razinama hijerarhijske strukture. Težinski koeficijenti se računaju za svaki element na datoj razini i isti se zatim koriste za određivanje tzv. kompozitnih relativnih težinskih koeficijenata elemenata na nižim razinama.

Pošto se postupak provodi do posljednje razine na kojem se nalaze alternative, na kraju se određuju kompozitni težinski koeficijenti svih alternativa. Zbroj ovih koeficijenata je 1, a donosioci odluke raspolažu sa dvije ključne informacije:

- a) poznat je relativan značaj svake alternative u odnosu na cilj smješten na vrhu hijerarhijske strukture (ocjena značajnosti),
- b) utvrđen je redoslijed alternativa po značaju (rangiranje).

Ova metoda spada ima sposobnost identificirati i analizirati nekonzistentnost donositelja odluke u procesu uspoređivanja elemenata hijerarhijske strukture. Čovjek je, naime, rijetko konzistentan pri procjenjivanju vrijednosti ili odnosa kvalitativnih elemenata u hijerarhijskoj strukturi. Analitički hijerarhijski proces na određen način ublažava ovaj problem tako što odmjerava stupanj nekonzistentnosti i o tome obavještava donosioca odluka.

Kada bi postojala mogućnost da se precizno odrede vrijednosti težinskih koeficijenata svih elemenata koji se međusobno uspoređuju na datoj razini hijerarhijske strukture, svojstvene vrijednosti matrice (4) bile bi potpuno konzistentne. Međutim, ako se primjerice tvrdi da je A mnogo većeg značaja od B , da je B nešto većeg značaja od C , i da je C nešto većeg značaja od A , nastaje nekonzistentnost u rješavanju problema i smanjuje se pouzdanost rezultata. Opći je stav da redundancija uspoređivanja u parovima čini ovu metodu ne previše osjetljivom na greške u prosuđivanju. Greške u prosuđivanju se mogu mjeriti na način da se proračunava indeks konzistentnosti za dobivenu matricu, a zatim se računa i stupanj konzistentnosti.

Da bi se izračunao stupanj konzistentnosti CR , prvo treba izračunati indeks konzistentnosti CI prema izrazu:

$$CI = \frac{\lambda_{\max} - n}{n - 1} \quad (10)$$

gdje je λ_{\max} najveća svojstvena vrijednost matrice relativnih važnosti. Kao što je već rečeno, što je λ_{\max} bliže broju n , manja će biti nekonzistentnost.

Da bi se izračunalo λ_{\max} , prvo je potrebno pomnožiti matricu uspoređivanja sa vektorom težinskih koeficijenata da bi se odredio vektor b :

$$\begin{bmatrix} a_{11} & a_{12} & \cdot & \cdot & a_{1n} \\ a_{21} & a_{22} & \cdot & \cdot & a_{2n} \\ \cdot & \cdot & & & \cdot \\ \cdot & \cdot & & & \cdot \\ a_{n1} & a_{n2} & \cdot & \cdot & a_{nn} \end{bmatrix} \cdot \begin{bmatrix} w_1 \\ w_2 \\ \cdot \\ \cdot \\ w_n \end{bmatrix} = \begin{bmatrix} b_1 \\ b_2 \\ \cdot \\ \cdot \\ b_n \end{bmatrix} \quad (11)$$

Dijeljenjem korespondentnih elemenata vektora b i w dobiva se:

$$\begin{bmatrix} b_1/w_1 \\ b_2/w_2 \\ \cdot \\ \cdot \\ b_n/w_n \end{bmatrix} = \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \cdot \\ \cdot \\ \lambda_n \end{bmatrix} \quad (12)$$

te je konačno:

$$\lambda_{\max} = \frac{1}{n} \sum_{i=1}^n \lambda_i \quad (13)$$

Zamjenom vrijednosti λ_{\max} iz relacije (13) u relaciju (10) određuje se indeks konzistentnosti, CI . Konačno, stupanj konzistentnosti, CR , predstavlja odnos indeksa konzistentnosti, CI , i slučajnog indeksa, RI :

$$CR = \frac{CI}{RI} \quad (14)$$

Slučajni indeks, RI , zavisi od reda matrice, a preuzima se iz tablice 4.3.3 u kojoj prvi red predstavlja red matrice uspoređivanja, a drugi slučajne indekse [13].

Tablica 4.3.3. Slučajni indeksi

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0,0	0,0	0,58	0,9	1,12	1,24	1,32	1,41	1,45	1,49	1,51	1,48	1,56	1,57	1,59

Ako je stupanj konzistentnosti, CR , manji od 0,10 rezultat se smatra dovoljno točnim i nema potrebe za korekcijama u uspoređivanju i ponavljanju proračuna.

4.3.5 Posebno prilagođeni *AHP* alat za hijerarhijsko modeliranje optimalnog rasporeda proizvodnih površina brodogradilišta

U okviru ovog rada izrađen je poseban alat za hijerarhijsko modeliranje prilagođen projektiranju rasporeda proizvodnih površina brodogradilišta unutar *Microsoft Excel*-a. Izrađeni alat ima način unosa ulaznih podataka upravo prilagođen za projektiranje rasporeda površina brodogradilišta. Isti, hijerarhijskim modeliranjem i korištenjem opisanih matematičkih temelja *AHP* metode dolazi do rezultata u obliku rang liste razmatranih najizglednijih alternativa rasporeda.

Korištenje alata započinje definiranjem kriterija, odnosno ograničenja i zahtjeva uključenih u realni problem. Analizom specifične problematike projektiranja rasporeda proizvodnih površina brodogradilišta utvrđeni su kriteriji koji najčešće uvjetuju izbor rješenja.

Navedeni kriteriji najčešće proizlaze iz:

- ograničenih financijskih sredstava namijenjenih restrukturiranju,
- nemogućnošću širenja izvan postojećih granica brodogradilišta ,
- potrebama zadržavanja i neometanja trenutne proizvodnje,
- zahtjeva za zadržavanjem postojećih objekata i sadržaja, a uz sve to nastoji se
- optimalno zadovoljiti tehnoložnost gradnje i proizvodne tokove.

Stoga je sam alat prilagođen za unos određenog broja postavljenih kriterija, unutar svijetlo plavih polja, kako je vidljivo iz slike 4.3.3.

Nakon što su definirani kriteriji pristupa se procjeni njihovih međusobnih omjera, korištenjem *Saaty*-jeve skale, unutar narančastih polja. Navedena procjena vrši se nakon utvrđivanja ciljne tehnološke razine te nakon utvrđivanja posebnih ograničenja postavljenih od strane uprave brodogradilišta.

Primjerice, zaokružena pozicija crvenom bojom prikazuje omjer važnosti, prema *Saaty*-jevoj skali, između kriterija 3 i kriterija 2. Na isti način se kriteriji uspoređuju u parovima, svaki sa svakim. Naravno, u poljima koja se nalaze na dijagonali, odnosno gdje se uspoređuju kriteriji sami sa sobom, upisuje se omjer 1:1.

PROCJENA OMJERA TEŽINA KRITERIJA (Saaty-jeva skala)						
		KRITERIJ 1	KRITERIJ 2	KRITERIJ 3	KRITERIJ 4	KRITERIJ 5
		1	2	3	4	5
KRITERIJ 1	1	1:1	1:2	1:3	1:4	1:5
KRITERIJ 2	2	2:1	2:2	2:3	2:4	2:5
KRITERIJ 3	3	3:1	3:2	3:3	3:4	3:5
KRITERIJ 4	4	4:1	4:2	4:3	4:4	4:5
KRITERIJ 5	5	5:1	5:2	5:3	5:4	5:5

OMJERI TEŽINA KRITERIJA
K_1
K_2
K_3
K_4
K_5

Slika 4.3.3. Izračun omjera težina kriterija unutar prilagođenog AHP alata

Cilj procijene međusobnih omjera postavljenih kriterija jest utvrđivanje njihovih omjera težina, K_{1-5} . Najčešće su ti kriteriji kontradiktorni i potrebno je procijeniti koji će se kriteriji favorizirati, što kod modernizacije postojećeg brodogradilišta isključivo ovisi o strateškim odlukama rukovodstava te ograničenjima brodogradilišta samog. Stoga je navedene procjene nužno izvoditi u suradnji s ekspertima iz brodogradilišta za koje se projektiranje rasporeda proizvodnih površina izvodi te uz korištenje tablice 4.3.1. Nakon izvršene procjene omjeri težina se automatski izračunavaju u okviru ovog alata te se prikazuju u stupcu s desne strane slike 4.3.3. unutar svijetlo zelenih polja.

Dobiveni omjeri težina omogućuju rangiranje kriterija prema važnosti, odnosno na taj način može se ustanoviti koje kriterije odabrane alternative, tj. varijante od 1 do 20, moraju prvenstveno zadovoljavati da bi potencijalno konkurirale za optimalno rješenje.

Nadalje, u okviru prilagođenog alata, vrši se uspoređivanje u parovima preuzetih najizglednijih alternativa iz prethodne faze predložene metodologije. Navedeno uspoređivanje se vrši u prilagođenom sučelju koje je prikazano na slici 4.3.4., također korištenjem Saaty-jeve skale. Primjerice, na spomenutoj slici je zaokružena pozicija crvenom bojom koja prikazuje omjer važnosti između varijante 11 i varijante 10 unutar koje se upisuje odgovarajući broj iz Saaty-jeve skale. Na isti se način i u svim ostalim narančastim poljima navedene slike vrši uspoređivanje, gdje svako polje određuje sučeljavanje dvije varijante. Takvih prilagođenih sučelja, koje je potrebno ispuniti, ima onoliko koliko i postavljenih kriterija. Dakle u prvom sučelju vrši se usporedba varijanti na temelju kriterija 1, u drugom, na temelju kriterija 2 itd., sve do posljednjeg kriterija.

Rezultati uspoređivanja automatski se izračunavaju i prikazuju u stupcu s desne strane unutar svijetlo zelenih polja spomenute slike, A_{k-1} do A_{k-20} , te predstavljaju lokalne prioritete pojedinih varijanti rješenja s obzirom na promatrani kriterij k .

Na temelju pojedinih lokalnih prioriteta moguće je rangirati varijante na način da se vidi kojim redoslijedom zadovoljavaju jedan, lokalno, promatrani kriterij. Odnosno može se ustanoviti koja varijanta će najbolje zadovoljavati prvi kriterij, zatim koja će najbolje zadovoljavati drugi kriterij, itd.

Međutim, cilj je odrediti varijantu koja će optimalno zadovoljiti svih pet postavljenih kriterija istovremeno, a za što služi posljednje posebno prilagođeno sučelje.

USPOREDBA U PAROVIMA PO KRITERIJU Br. k $k=1...5$		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	LOKALNI PRIORITETI ZA k -TI KRITERIJ
VARIJANTA	1	VARIJANTA	VARIJANTA	VARIJANTA	VARIJANTA	VARIJANTA	VARIJANTA	VARIJANTA	VARIJANTA	VARIJANTA	VARIJANTA	VARIJANTA	VARIJANTA	VARIJANTA	VARIJANTA	VARIJANTA	VARIJANTA	VARIJANTA	VARIJANTA	VARIJANTA	VARIJANTA	
VARIJANTA	1	1:1	1:2	1:3	1:4	1:5	1:6	1:7	1:8	1:9	1:10	1:11	1:12	1:13	1:14	1:15	1:16	1:17	1:18	1:19	1:20	A_{k-1}
VARIJANTA	2	2:1	2:2	2:3	2:4	2:5	2:6	2:7	2:8	2:9	2:10	2:11	2:12	2:13	2:14	2:15	2:16	2:17	2:18	2:19	2:20	A_{k-2}
VARIJANTA	3	3:1	3:2	3:3	3:4	3:5	3:6	3:7	3:8	3:9	3:10	3:11	3:12	3:13	3:14	3:15	3:16	3:17	3:18	3:19	3:20	A_{k-3}
VARIJANTA	4	4:1	4:2	4:3	4:4	4:5	4:6	4:7	4:8	4:9	4:10	4:11	4:12	4:13	4:14	4:15	4:16	4:17	4:18	4:19	1/3	A_{k-4}
VARIJANTA	5	5:1	5:2	5:3	5:4	5:5	5:6	5:7	5:8	5:9	5:10	5:11	5:12	5:13	5:14	5:15	5:16	5:17	5:18	5:19	5:20	A_{k-5}
VARIJANTA	6	6:1	6:2	6:3	6:4	6:5	6:6	6:7	6:8	6:9	6:10	6:11	6:12	6:13	6:14	6:15	6:16	6:17	6:18	6:19	6:20	A_{k-6}
VARIJANTA	7	7:1	7:2	7:3	7:4	7:5	7:6	7:7	7:8	7:9	7:10	7:11	7:12	7:13	7:14	7:15	7:16	7:17	7:18	7:19	7:20	A_{k-7}
VARIJANTA	8	8:1	8:2	8:3	8:4	8:5	8:6	8:7	8:8	8:9	8:10	8:11	8:12	8:13	8:14	8:15	8:16	8:17	8:18	8:19	8:20	A_{k-8}
VARIJANTA	9	9:1	9:2	9:3	9:4	9:5	9:6	9:7	9:8	9:9	9:10	9:11	9:12	9:13	9:14	9:15	9:16	9:17	9:18	9:19	9:20	A_{k-9}
VARIJANTA	10	10:1	10:2	10:3	10:4	10:5	10:6	10:7	10:8	10:9	10:10	10:11	10:12	10:13	10:14	10:15	10:16	10:17	10:18	10:19	10:20	A_{k-10}
VARIJANTA	11	11:1	11:2	11:3	11:4	11:5	11:6	11:7	11:8	11:9	11:10	11:11	11:12	11:13	11:14	11:15	11:16	11:17	11:18	11:19	11:20	A_{k-11}
VARIJANTA	12	12:1	12:2	12:3	12:4	12:5	12:6	12:7	12:8	12:9	12:10	12:11	12:12	12:13	12:14	12:15	12:16	12:17	12:18	12:19	12:20	A_{k-12}
VARIJANTA	13	13:1	13:2	13:3	13:4	13:5	13:6	13:7	13:8	13:9	13:10	13:11	13:12	13:13	13:14	13:15	13:16	13:17	13:18	13:19	13:20	A_{k-13}
VARIJANTA	14	14:1	14:2	14:3	14:4	14:5	14:6	14:7	14:8	14:9	14:10	14:11	14:12	14:13	14:14	14:15	14:16	14:17	14:18	14:19	14:20	A_{k-14}
VARIJANTA	15	15:1	15:2	15:3	15:4	15:5	15:6	15:7	15:8	15:9	15:10	15:11	15:12	15:13	15:14	15:15	15:16	15:17	15:18	15:19	15:20	A_{k-15}
VARIJANTA	16	16:1	16:2	16:3	16:4	16:5	16:6	16:7	16:8	16:9	16:10	16:11	16:12	16:13	16:14	16:15	16:16	16:17	16:18	16:19	16:20	A_{k-16}
VARIJANTA	17	17:1	17:2	17:3	17:4	17:5	17:6	17:7	17:8	17:9	17:10	17:11	17:12	17:13	17:14	17:15	17:16	17:17	17:18	17:19	17:20	A_{k-17}
VARIJANTA	18	18:1	18:2	18:3	18:4	18:5	18:6	18:7	18:8	18:9	18:10	18:11	18:12	18:13	18:14	18:15	18:16	18:17	18:18	18:19	18:20	A_{k-18}
VARIJANTA	19	19:1	19:2	19:3	19:4	19:5	19:6	19:7	19:8	19:9	19:10	19:11	19:12	19:13	19:14	19:15	19:16	19:17	19:18	19:19	19:20	A_{k-19}
VARIJANTA	20	20:1	20:2	20:3	20:4	20:5	20:6	20:7	20:8	20:9	20:10	20:11	20:12	20:13	20:14	20:15	20:16	20:17	20:18	20:19	20:20	A_{k-20}

Slika 4.3.4. Izračun lokalnih prioriteta s obzirom na pojedine kriterije unutar prilagođenog AHP alata

Dakle, utvrđeni rezultati lokalnih prioriteta, zajedno sa utvrđenim omjerima težina pojedinih kriterija automatski se prenose u posebno sučelje, slika 4.3.5, gdje su prikazani kao ulazni parametri za konačni izračun ukupnih prioriteta.

OMJERI TEŽINA KRITERIJA		K1	K2	K3	K4	K5	UKUPNI PRIORITETI ALTERNATIVA
LOKALNI PRIORITETI ALTERNATIVA PO POJEDINIM KRITERIJIMA		KRITERIJ 1	KRITERIJ 2	KRITERIJ 3	KRITERIJ 4	KRITERIJ 5	
ALTERNATIVE	VARIJANTA 1	A ₁₋₁	A ₂₋₁	A ₃₋₁	A ₄₋₁	A ₅₋₁	P ₁
	VARIJANTA 2	A ₁₋₂	A ₂₋₂	A ₃₋₂	A ₄₋₂	A ₅₋₂	P ₂
	VARIJANTA 3	A ₁₋₃	A ₂₋₃	A ₃₋₃	A ₄₋₃	A ₅₋₃	P ₃
	VARIJANTA 4	A ₁₋₄	A ₂₋₄	A ₃₋₄	A ₄₋₄	A ₅₋₄	P ₄
	VARIJANTA 5	A ₁₋₅	A ₂₋₅	A ₃₋₅	A ₄₋₅	A ₅₋₅	P ₅
	VARIJANTA 6	A ₁₋₆	A ₂₋₆	A ₃₋₆	A ₄₋₆	A ₅₋₆	P ₆
	VARIJANTA 7	A ₁₋₇	A ₂₋₇	A ₃₋₇	A ₄₋₇	A ₅₋₇	P ₇
	VARIJANTA 8	A ₁₋₈	A ₂₋₈	A ₃₋₈	A ₄₋₈	A ₅₋₈	P ₈
	VARIJANTA 9	A ₁₋₉	A ₂₋₉	A ₃₋₉	A ₄₋₉	A ₅₋₉	P ₉
	VARIJANTA 10	A ₁₋₁₀	A ₂₋₁₀	A ₃₋₁₀	A ₄₋₁₀	A ₅₋₁₀	P ₁₀
	VARIJANTA 11	A ₁₋₁₁	A ₂₋₁₁	A ₃₋₁₁	A ₄₋₁₁	A ₅₋₁₁	P ₁₁
	VARIJANTA 12	A ₁₋₁₂	A ₂₋₁₂	A ₃₋₁₂	A ₄₋₁₂	A ₅₋₁₂	P ₁₂
	VARIJANTA 13	A ₁₋₁₃	A ₂₋₁₃	A ₃₋₁₃	A ₄₋₁₃	A ₅₋₁₃	P ₁₃
	VARIJANTA 14	A ₁₋₁₄	A ₂₋₁₄	A ₃₋₁₄	A ₄₋₁₄	A ₅₋₁₄	P ₁₄
	VARIJANTA 15	A ₁₋₁₅	A ₂₋₁₅	A ₃₋₁₅	A ₄₋₁₅	A ₅₋₁₅	P ₁₅
	VARIJANTA 16	A ₁₋₁₆	A ₂₋₁₆	A ₃₋₁₆	A ₄₋₁₆	A ₅₋₁₆	P ₁₆
	VARIJANTA 17	A ₁₋₁₇	A ₂₋₁₇	A ₃₋₁₇	A ₄₋₁₇	A ₅₋₁₇	P ₁₇
	VARIJANTA 18	A ₁₋₁₈	A ₂₋₁₈	A ₃₋₁₈	A ₄₋₁₈	A ₅₋₁₈	P ₁₈
	VARIJANTA 19	A ₁₋₁₉	A ₂₋₁₉	A ₃₋₁₉	A ₄₋₁₉	A ₅₋₁₉	P ₁₉
	VARIJANTA 20	A ₁₋₂₀	A ₂₋₂₀	A ₃₋₂₀	A ₄₋₂₀	A ₅₋₂₀	P ₂₀

Slika 4.3.5. Izračun ukupnih prioriteta unutar prilagođenog AHP alata

Primjer izračuna ukupnih prioriteta za varijantu 1 dan je sljedećim izrazom unutar kojega su uključeni elementi slike 4.3.5. zaokruženi crvenom bojom:

$$P_1 = A_{1-1} \cdot K_1 + A_{2-1} \cdot K_2 + A_{3-1} \cdot K_3 + A_{4-1} \cdot K_4 + A_{5-1} \cdot K_5 \quad (15)$$

gdje je:

P_1 - ukupni prioritet varijante 1,

A_{1-1} - lokalni prioritet varijante 1 s obzirom na prvi kriterij,

- A_{2-1} - lokalni prioritet varijante 1 s obzirom na drugi kriterij,
- A_{3-1} - lokalni prioritet varijante 1 s obzirom na treći kriterij,
- A_{4-1} - lokalni prioritet varijante 1 s obzirom na četvrti kriterij,
- A_{5-1} - lokalni prioritet varijante 1 s obzirom na peti kriterij,
- K_{1-5} - vrijednost težine pojedinog kriterija

Na isti način izračunavaju se i ukupni prioriteti ostalih varijanti. Konačno temeljem utvrđenih prioriteta, $P_1... P_{20}$, izdvaja se rješenje koje ima najveću vrijednost, a što znači najbolje udovoljavanje postavljenim kriterijima. Takvo rješenje smatra se optimalnim. Također je moguće automatski posložiti sve varijante na temelju dobivenih rezultata na način da tvore rang ljestvicu, odnosno od one koja najbolje udovoljava kriterijima, pa sve do one koja najlošije udovoljava istim.

Izrađeni prilagođeni alat doprinosi pojednostavljenom donošenju složene odluke kod odabira optimalnog projekta rasporeda proizvodnih površina brodogradilišta na način da kreira prilagođeni pristup unosu podataka te izboru optimalnog rješenja.

Stabilnost odabranog rješenja, odnosno rang ljestvice, utvrđuje se u sljedećoj fazi ove metodologije.

4.4 FAZA 4 – Utvrđivanje stabilnosti projektiranog rasporeda proizvodnih površina brodogradilišta primjenom analize osjetljivosti

4.4.1 Uvod

Analiza osjetljivosti provodi se u četvrtoj fazi predložene metodologije, a s ciljem da se utvrdi u kojoj mjeri se promjene ulaznih podataka odražavaju na ukupne prioritete alternativa, odnosno kako bi se utvrdila stabilnost odabranog rješenja.

Analiza osjetljivosti je metoda operacijskih istraživanja skupine linearnog programiranja, koja proučava kako promjene parametara modela, odnosno vrijednosti značajki, utječu na optimalno rješenje linearnog programiranja, [117].

Analiza osjetljivosti može biti korisna u različitim slučajevima, primjerice:

- pri projektiranju novog rasporeda proizvodnih površina,
- pri analizi postojećeg rasporeda proizvodnih površina,
- kao pomoć u procesu izbora optimalnog projektnog rješenja,
- za potrebe procjene rizika, itd.

Nadalje, u postupku provođenja analize osjetljivosti promjenljive varijable su:

- vrijednosti ulaznih parametara u okviru hijerarhijskog modela,
- vrijednosti značajki kriterija hijerarhijskog modela i
- ostale vrijednosti koje definiraju ili ograničavaju raspored proizvodnih površina.

Svrha i rezultati primjene metode analize osjetljivosti mogu biti sljedeći:

- utvrđivanje stabilnosti odabranog projektnog rješenja,
- pojednostavljivanje hijerarhijskog modela,
- identificiranje novih vrijednosti značajki hijerarhijskog modela temeljem eksperimenata,
- utvrđivanje kritičnih značajki hijerarhijskog modela, itd.

Pri tome, razlikuju se dvije varijante metode analize osjetljivosti vezano za pristup njihova provođenja, a odluka često ovisi o karakteristikama slučaja na koji se primjenjuje, i to, [118]:

- Analitička analiza osjetljivosti:

- za dobro definirane sustave,
- rješavanju problema pristupa se parcijalnim derivacijama, (16),

$$S_x^F = \frac{\partial F}{\partial x}, \quad (16)$$

pri čemu S definira funkciju osjetljivosti, odnosno intenzitet promjene, ciljne funkcije F ovisno o promjenama parametra x .

- Empirijska analiza osjetljivosti:

- eksperimentiranjem se analizira utjecaj promjene ulaznih parametara na izbor optimalnog projektnog rješenja ,
- prikladnija za složene sustave i one koji nisu precizno definirani.

Za potrebe predložene metodologije prikladnija je te stoga i predložena upravo empirijska analiza osjetljivosti.

4.4.2 Provođenje empirijske analize osjetljivosti

Da bi se došlo do zaključka da li je rang lista alternativa dovoljno stabilna u odnosu na određene promjene ulaznih podataka, provodi se eksperimentalna analiza osjetljivosti gdje se u okviru hijerarhijskog modela analitičkim hijerarhijskim procesom izračunavaju prioriteta varijanti za brojne različite kombinacije ulaznih podataka.

U okviru ovoga rada predlaže se, radi brže analize i provjere konačnog rješenja, korištenje specijaliziranog računalnog alata. Jedan takav alat je *Expert Choice software* [119], uz čiju podršku se analiza osjetljivosti provodi brzo i efikasno. Isti je korišten za provjeru predložene metodologije na realnom primjeru. Posebnu vrijednost ovom programu daju različite mogućnosti provođenja analize osjetljivosti koje se temelje na vizualizaciji posljedica

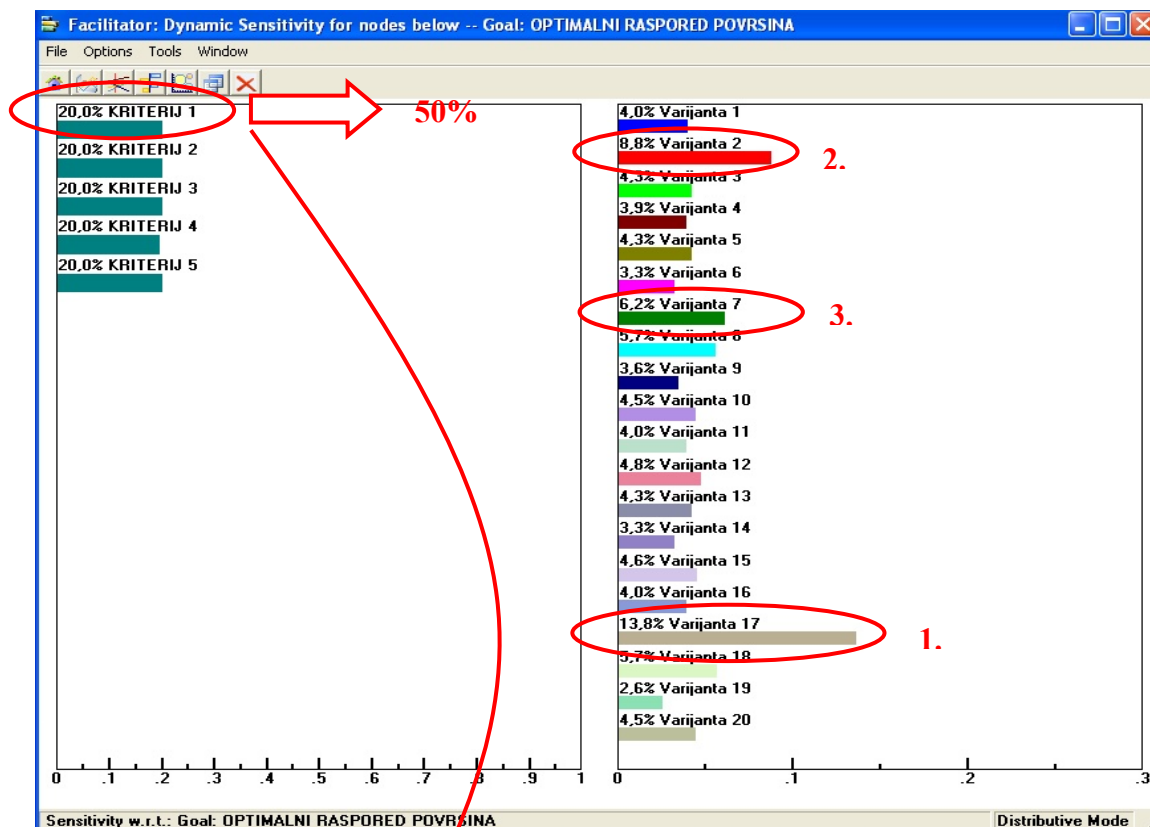
promjena ulaznih podataka. Za potrebe metodologije predlažu se četiri relevantna tipa analize osjetljivosti i to:

- dinamička analiza osjetljivosti
- analiza izvedbene osjetljivosti
- analiza dijagramom stupnja osjetljivosti
- analiza dijagramom sučeljavanja

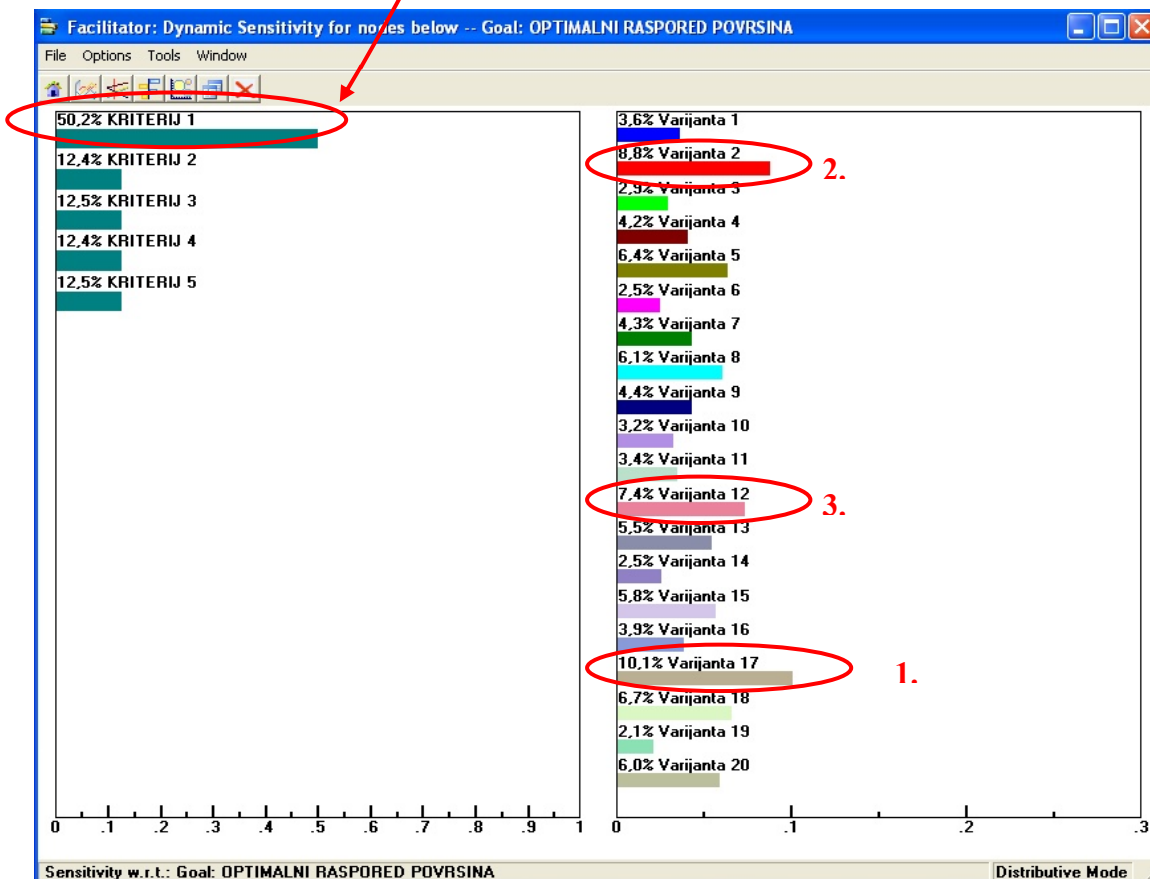
4.4.3 Dinamička analiza osjetljivosti

Dinamička analiza osjetljivosti (engl. *Dynamic Sensitivity Analysis*) koristi se na način da se prioriteti dinamički mijenjaju direktno na zaslonu računala i promatra se na koji način te promjene utječu na prioritete alternativa i njihovo rangiranje. Primjerice, kada bi se krenulo od pretpostavke da svi kriteriji imaju jednake prioritete, tzv. slučaj 1, kako je prikazano na slici 4.4.1. s lijeve strane (20%), tada bi važnosti pojedinih alternativa, temeljem njihovih osnovnih karakteristika, iznosile upravo kako je dano s desne strane iste slike. U tom slučaju, vidljivo je da su Varijanta 7 (6,2 %), Varijanta 2 (8,8 %), te posebno Varijanta 17 (13,8 %) superiornije od ostalih. Međutim povećavanjem, primjerice prioriteta Kriterija 1 do vrijednosti 50%, slučaj 2, dinamičkim povećavanjem istog na zaslonu, može se promatrati što se na tom putu događa s izmjenama u prioritetima alternativa. Odnosno može se zaključiti kako se superiornost među alternativama mijenja favoriziranjem Kriterija 1, slika 4.4.2. Vidi se da su se na taj način dogodile određene promjene. Primjerice Varijanta 7 se izmjestila niže na rang ljestvici prioriteta, te se na njeno mjesto popela Varijanta 12. Međutim Varijanta 2 te Varijanta 17, iako manje dominantne, ostale su još uvijek na drugom odnosno prvom mjestu temeljem prioriteta. Zaključak prikaza bio bi da se povećanjem prioriteta Kriterija 1 utvrđuje dovoljna stabilnost Varijante 17, koja se odabire te potvrđuje kao optimalno rješenje. Navedenim prikazom htio se približiti način na koji se koristi opcija dinamičke analize osjetljivosti.

Opisani postupak, kod provjere predložene metodologije, izvršen je prema svim kriterijima, i to njihovim povećavanjem i njihovim smanjivanjem s ciljem da se što potpunije provjeri odabrano rješenje, a što je elaborirano u 5. poglavlju.




Slika 4.4.1. Prikaz zaslona pri izvođenju dinamičke analize osjetljivosti, slučaj 1.



Slika 4.4.2. Prikaz zaslona pri izvođenju dinamičke analize osjetljivosti, slučaj 2.

4.4.4 Analiza izvedbene osjetljivosti


Analiza izvedbene osjetljivosti (engl. *Performance Sensitivity Analysis*) pokazuje na koji način su alternative međusobno rangirane zasebno po pojedinim kriterijima te zaključno i po svim kriterijima zajedno. Moguće je također izvoditi promjene pojedinog kriterija te pratiti na koji način takva promjena utječe kako na rangiranje po pojedinim kriterijima tako i ukupno. Na slici 4.4.3., dan je prikaz zaslona kod analize izvedbene osjetljivosti. S desne strane slike vidljiv je rangirani popis varijanti temeljem svih kriterija. Svakoj varijanti dodijeljena je vlastita boja, te je na taj način, krećući se od desna na lijevo, moguće pratiti kako je pojedina varijanta rangirana na ucrtanim vertikalama koje predstavljaju pojedine kriterije. Primjerice, ako pratimo varijantu 2, kojoj je dodijeljena crvena boja, zaključujemo da se ona temeljem svih kriterija (pozicija 6.) nalazi na drugom mjestu. Nadalje prateći je s desna na lijevo uočava se da na sljedećoj vertikali (pozicija 5.) udovoljava kriteriju 5 jednako kao i većina ostalih varijanti. Na vertikali koji predstavlja kriterij 4 (pozicija 4.) zauzima drugo mjesto, zatim vrlo loše udovoljava kriteriju 3 (pozicija 3), te konačno po kriteriju 2 (pozicija 2.) zauzima drugo mjesto, te prema kriteriju 1 (pozicija 1.), treće.



Slika 4.4.3. Prikaz zaslona pri analizi izvedbene osjetljivosti

4.4.5 Analiza dijagramom stupnja osjetljivosti


Dijagram stupnja osjetljivosti (engl. *Gradient Sensitivity Graph*) prikazuje prioritete alternativa u zavisnosti od po jednog odabranog kriterija. Iz ovog dijagrama moguće je iščitati u kojem trenutku, s kojom vrijednosti prioriteta odabranog kriterija dolazi do promjene u rangiranju, tj. moguće je iščitati u kojim intervalima vrijednosti prioriteta kriterija dominiraju određene varijante. Ako je nužna velika promjena da dođe do izmjene optimalnog rješenja, a koja nije opravdana tada se može zaključiti da je rješenje dovoljno stabilno. Primjerice, kako je prikazano na slici 4.4.4., prateći dodijeljene boje, može se zaključiti da se, prema kriteriju 1, varijanta 17 smatra optimalnom u 1. intervalu kriterija jer ima najveće vrijednosti po ordinati koja predstavlja prioritete varijanti. U 2. intervalu optimalnom se smatra varijanta 2, dok se u 3. intervalu optimalnom smatra varijanta 12. Rangirani ispis alternativa s desne strane slike 4.4.4. predstavlja rang listu prioriteta alternativa ako bi se u obzir uzeo isključivo razmatrani kriterij. Navedeno je posebno opisano kod provjere metodologije, što je dano u 5. poglavlju.



Slika 4.4.4. Prikaz zaslona pri analizi dijagramom stupnja osjetljivosti

4.4.6 Analiza dijagramom sučeljavanja

Analiza dijagramom sučeljavanja (engl. *Head-to-Head Graph*) prikazuje kako se odabrane dvije varijante međusobno odnose temeljem odabranih kriterija, te je također prikazan iznos u postocima koliko je jedina bolja od druge. Primjerice, kako je prikazano na slici 4.4.5., dijagramom sučeljavanja, za varijantu 2 i varijantu 8, može se zaključiti da temeljem kriterija 1 varijanta 2 ima malenu prednost. Zatim, varijanta 2 ima značajnu prednost temeljem kriterija 2. Temeljem kriterija 3 prednost je na strani varijante 8, a dok je prema preostalih dva kriterija ponovno varijanta 2 dominantnija. Ukupna prednost prikazana je sivom bojom neposredno iznad apscise te se ona dodjeljuje varijanti 2.



Slika 4.4.5. Prikaz dijagrama sučeljavanja varijante 2 i varijante 8

Iako je na taj način moguće usporediti sve varijante međusobno, a što bi zahtijevalo znatan utrošak vremena, u predloženoj metodologiji se preporuča uspoređivati samo odabrano rješenje iz prethodne faze s ostalim rješenjima. Na taj način vrši se 19 međusobnih usporedbi na osnovu kojih se vrše zaključci direktno vezani uz provjeru predloženog rješenja. Taj postupak je izvršen kod provjere metodologije u 5. poglavlju.

4.5 Sažetak

U ovom poglavlju dan je prikaz predložene metodologije za projektiranje optimalnog rasporeda proizvodnih površina brodogradilišta koja se provodi kroz četiri definirane faze. U svakoj fazi, za postizanje željenog cilja, opisane su odabrane metode i alati s pripadajućim matematičkim temeljima i formulacijama. Nadalje, odabrane metode i alati posebno su prilagođeni problemu projektiranja rasporeda proizvodnih površina brodogradilišta.

U prvoj fazi, metodom anketiranja značajnog broja relevantnih znanstvenih savjetnika i suradnika, te stručnjaka iz razmatranog polja brodogradnje, utvrđeni su posebni težinski faktori, odnosno ponderi kojima se definira odnos bliskosti točno odabranih proizvodnih površina sa stajališta optimalnih tokova osnovnog brodograđevnog procesa. Utvrđeni odnosi bliskosti i pripadajući težinski faktori predloženi su za korištenje u okviru druge faze za procjenu u kojoj mjeri generirana projektna rješenja zadovoljavaju utvrđena saznanja o optimalnim proizvodnim tokovima, kroz tzv. *SLP* ocjenu rasporeda površina. Navedena, generirana, odnosno sva teoretski moguća projektna rješenja rezultiraju korištenjem metode sistematskog planiranja rasporeda površina. Među generiranim rješenjima utvrđuje se dvadeset najizglednijih rješenja temeljem *SLP* ocjene, te se ista predlažu za daljnje razmatranje. U trećoj fazi, vrši se utvrđivanje i analiza postojećih i postavljenih ograničenja, pomoću kriterija, na temelju kojih se hijerarhijskim modeliranjem utvrđuje takvo projektno rješenje koje optimalno udovoljava istima. Za hijerarhijsko modeliranje predloženo je korištenje metode analitičkog hijerarhijskog procesa. Na odabranom projektnom rješenju se, u okviru četvrte faze, vrši utvrđivanje njegove stabilnosti provođenjem analize osjetljivosti, čime se potvrđuje i robusnost predložene metodologije. Zaključno, moguće je daljnje lociranje proizvodnih tokova na predloženom projektnom rješenju.

Na temelju izloženih formulacija i opisa postupka predložena metodologija je primijenjena kod projektiranja rasporeda proizvodnih površina postojećeg brodogradilišta, a u okviru njegove tehnološke modernizacije što je elaborirano u sljedećem poglavlju.

5 PROVJERA PREDLOŽENE METODOLOGIJE NA PRIMJERU POSTOJEĆEG BRODOGRADILIŠTA

5.1 FAZA 1 – Analiza ulaznih podataka i implementacija utvrđenih odnosa bliskosti razmatranih proizvodnih površina

Predložena metodologija primijenjena je pri rješavanju realnog problema kod postojećeg brodogradilišta gdje je izrađivan tehnološki projekt modernizacije koji obuhvaća i optimizaciju proizvodnih tokova procesa odnosno izradu projekta optimizacije rasporeda proizvodnih površina.

Kod tehnološke modernizacije postojećeg brodogradilišta postoji čitav niz ograničenja i zahtjeva koji kod osnivanja novog brodogradilišta ne postoje. Prije svega postoje objekti koji se prema zadatku ne mogu pomicati ili promijeniti, postojeća proizvodnja tijekom modernizacije ne smije imati značajnije zastoje, zatim nije poželjno širenje izvan postojećih površina brodogradilišta, te naravno namjenska investicijska sredstva su uglavnom ograničena. Navedena ograničenja čine projektiranje rasporeda proizvodnih površina vrlo kompleksnim, međutim prikladnim za provjeru predložene metodologije.

5.1.1 Osnovne značajke rasporeda površina postojećeg brodogradilišta

Razmatrano postojeće brodogradilište je geografski smješteno u uvali i položeno skoro u potpunosti u pravcu istok-zapad. Prikaz zatečenog stanja postojećeg brodogradilišta dan je na slici 5.1.1.

Tok čeličnog materijala ne prati suvremenu tehnoložnost gradnje broda. Sa glavnog skladišta, nedovoljnog kapaciteta, (poz. br.1) svi čelični limovi ulaze vagonom u radionicu za rezanje i oblikovanje limova (poz. br. 2). Radionica je opremljena samo jednim strojem za rezanje i nekolicinom strojeva za oblikovanje što ne osigurava dovoljnu propusnost prema zahtjevanom proizvodnom programu (poglavlje 5.1.2). Zbog toga je potrebno predvidjeti dodatnu, novu radionicu za rezanje profila (poz. br. 4).

Profili se samo djelomično obrađuju u radionici za obradu profila (poz. br. 3) koje nije opremljena nikakvim suvremenim automatiziranim strojem za rezanje ili oblikovanje je se većina profila obrađuje kod kooperanata izvan brodogradilišta. Potrebno je izvesti modernizaciju i reorganizaciju ove radionice kako bi bila na prihvatljivoj tehnološkoj razini i preuzela kompletnu obradu profila. Iz ovih radionica i limovi i profili odlaze ili u radionicu predmontaže (poz. br. 6) ili direktno na navoze (poz. br. 14) jer ne postoji radionica malepredmontaže te radionica za izradu panela (poz. br. 5), što je velik tehnološki nedostatak promatranog brodogradilišta. Nadalje, radionica predmontaže (poz. br. 6) je prema zahtjevanom proizvodnom programu nedovoljnog kapaciteta, te se potrebno njeno produljenje.


Čelične cijevi sa glavnog skladišta (poz. br. 1) se odvoze kamionetom u vrlo malu radionicu za obradu cijevi (poz. br. 8) bitno dislociranu. Istu je potrebno povećati, modernizirati i reorganizirati. Zatim, zrnčenje i bojenje cijevnih sklopova i ostale opreme vrši se na neadekvatnim i otvorenim površinama.

Iako razmatrano brodogradilište posjeduje noviji transporter velike nosivosti, onemogućeno je ukupnjivanje sekcija do potrebne mase zbog nedostatka nosivosti dizalica na navozima (poz. br. 14). Nužno je povećanje nosivosti dizalica navoza te se u tu svrhu preporuča implementacija mostne dizalice minimalne nosivosti 120 t.

Budući ne postoji radionica za bojenje i zrnčenje sekcija (pozicija br. 7) isto se odvija na navozu i na otvorenim površinama, što nije više ekološki prihvatljivo. Površina za odlaganje sekcija (poz. br. 12) nije adekvatno cestovno povezana s navozima, tj. nije dovoljno široka da omogući pristup transporteru. Jedina površina na kojoj je moguće izvoditi ukupnjivanje, opremanje i/ili odlaganje gotovih sekcija jest površina (poz. br. 13) na čelu navoza.

Nakon porinuća plovni objekt se vezuje uz opremnu obalu (pozicija br. 10) gdje se nalaze i određene opremne radionice, uglavnom vrlo niske tehnološke razine. Limarska radionica (poz. br. 9) smještena je na 1. katu označene zgrade čime je otežana komunikacija gotovih dijelova, odnosno proizvoda ove radionice s opremnom obalom.

Brodogradilište raspolaze s velikim površinama na svom južnom djelu koje nisu adekvatno iskorištene jer nepostoji dobra cestovna povezanost. Na istim površinama se nalaze i radionice za obradu drvene građe te pripadajuća skladišta koja se više ne koriste (poz. br. 16).



Slika 5.1.1. Prikaz zatečenog stanja postojećeg brodogradilišta

Legenda:

1. Glavno skladište čeličnog materijala, nedovoljnog kapaciteta
2. Radionica za rezanje i oblikovanje limova
3. Radionica za obradu profila
4. Radionica za rezanje limova – nepostoji
5. Radionica za izradu panela – nepostoji
6. Radionica predmontaže – nedovoljnog kapaciteta
7. Radionica za zrnčenje i bojenje gotovih sekcija – nepostoji
8. Radionica za obradu cijevi – nedovoljnog kapaciteta
9. Limarska radionica
10. Opremna obala i ostale opremne radionice
11. Radionica za zrnčenje i bojenje opreme – nepostoji
12. Površina za odlaganje/ukrupnjivanje gotovih sekcija uz opremnu obalu
13. Površina za odlaganje sekcija prije montaže na navozu
14. Navozi
15. More
16. Radionica za obradu drvene građe s pripadajućim skladištem – nije u funkciji

Kompaktnost rasporeda površina promatranog brodogradilišta narušavaju:

- dvije, po veličini/dužini, različite opremne obale, locirane na suprotnim stranama uvala, što donekle slijede i opremne radionice (poz. br. 10 i br. 12),

- relativna dislociranost radionice predmontaže (poz. br. 6) u odnosu na glavne tokove materijala u izradi trupa plovniha objekata,
- neprikladnost glavnih tokova materijala u brodograđevnim radionicama (poz. br. 2 i br. 3),
- neuravnoteženost transportnih mogućnosti u cijelom proizvodnom procesu, posebno između dviju glavnih tehnoloških faza: predmontaže i montaže,
- nedovoljan kapacitet dizalica na navozima (poz. br. 14) što ima za posljedicu duga vremena gradnje plovniha objekata na navozu, te umanjuje mogućnost primjene suvremene metodologije gradnje plovniha objekata,
- česti povratni tokovi materijala u izradi trupa te međusobno "presijecanje" glavnih tokova,
- brojni povratni tokovi u opremanju koji se međusobno presijecaju i isprepliću,
- tokovi u remontu koji su pod utjecajem lociranosti opremne obale i plovniha dokova s jedne strane, te ključnih opremnih, odnosno remontnih radionica s druge strane.

S tehnološkog stajališta, obzirom na razmještaj proizvodnih površina i trenutni proizvodni tok, može se zaključiti da pojedine radionice nisu najpovoljnije locirane dok određene i ne postoje. Ovo je proizašlo postepenim širenjem kapaciteta pojedinih segmenata, bez dovoljnog sagledavanja sveukupnosti proizvodnog procesa. Zatečeno stanje ima karakteristike tehnološke razine 2 što se tiče rasporeda površina, prema tablici 4.1.3. Primjenom predložene metodologije na primjeru postojećeg brodogradilišta uključiti će se nedostajuće proizvodne površine te će se zajedno s postojećim bolje povezati u proizvodni proces. Pojedine proizvodne površine će se i cestovno povezati, a sve to u cilju da se podigne tehnološka razina sa broja 2 na broj 4.

5.1.2 Definiranje proizvodnog programa

Kako bi se mogao uspostaviti osnovni proizvodni tok brodograđevnog procesa pristupilo se je definiranju proizvodnog programa brodogradilišta uz relevantne zahtjeve i ograničenja.

Analizirane su tri varijante, A, B i C, proizvodnog programa promatranog brodogradilišta, tablice 5.1.1, 5.1.2. i 5.1.3., koje su posljedica dijelom već ugovorenih

brodova, a dijelom strateškog opredjeljenja i odluka uprave na koja će se tržišta pšotencijalno orjentirati u budućnosti.

Tehnološkom razradom pretpostavljenih proizvodnih programa došlo se do osnovnog dijagrama proizvodnog procesa prikazanog shematski na slici 5.1.2. Iz navedenog prikaza mogu se iščitati osnovne proizvodne površine, koja se, uz ostala ograničenja, moraju uzeti u obzir kod prikupljanja ulaznih podataka kako bi se iste, korištenjem predložene metodologije, optimalno smjestile u raspoloživ prostor brodogradilišta.

Prije svega, u suradnji s ekspertnim timom postojećeg brodogradilišta započelo se je s prikupljanjem ulaznih podataka o broju, nazivu, te pripadajućoj površini svake od radnih površina koje će se smještati u raspoloživi prostor postojećeg brodogradilišta uz poštivanje zadanih ograničenja za navedeni realni problem, Tablica 5.1.2.

Tablica 5.1.1. Zahtijevani proizvodni program promatranog brodogradilišta, varijanta A

Proizvod	Broj /god.	Netto masa čelika/objekt (t)	Ukupna netto masa čelika (t/god.)	Dužina (m)	Širina (m)	Visina (m)
Brod za prijevoz asfalta	2	2630	5260	108	18,6	10,6
Višenamjenski brod	1	740	740	67	12,4	6
UKUPNO NOVOGRADNJE			6000			
UKUPNO , BRUTO (20%)			7500			
<i>Specijalni plovni objekti (Al): Pilotski brod, jahta, trajekt, patrolni brod, katamaran, nadgrađa, te remont.</i>			25 t aluminija			

Tablica 5.1.2. Zahtijevani proizvodni program promatranog brodogradilišta, varijanta B

Proizvod	Broj /god.	Netto masa čelika/objekt (t)	Ukupna netto masa čelika (t/god.)	Dužina (m)	Širina (m)	Visina (m)
Brod za prijevoz asfalta	1	2600	2600	108	18,6	10,6
Brod za prijevoz automobila	1	2000	2000	125	20	15,7
Brod za prijevoz automobila 1	1	1100	1100	87	17,5	3,7
Remorker	1	300	300	30		
UKUPNO NOVOGRADNJE			6000			
UKUPNO Č, BRUTO (20%)			7500			
<i>Specijalni plovni objekti (Al): Pilotski brod, jahta, trajekt, patrolni brod, katamaran, nadgrađa, te remont.</i>			25 t aluminija			

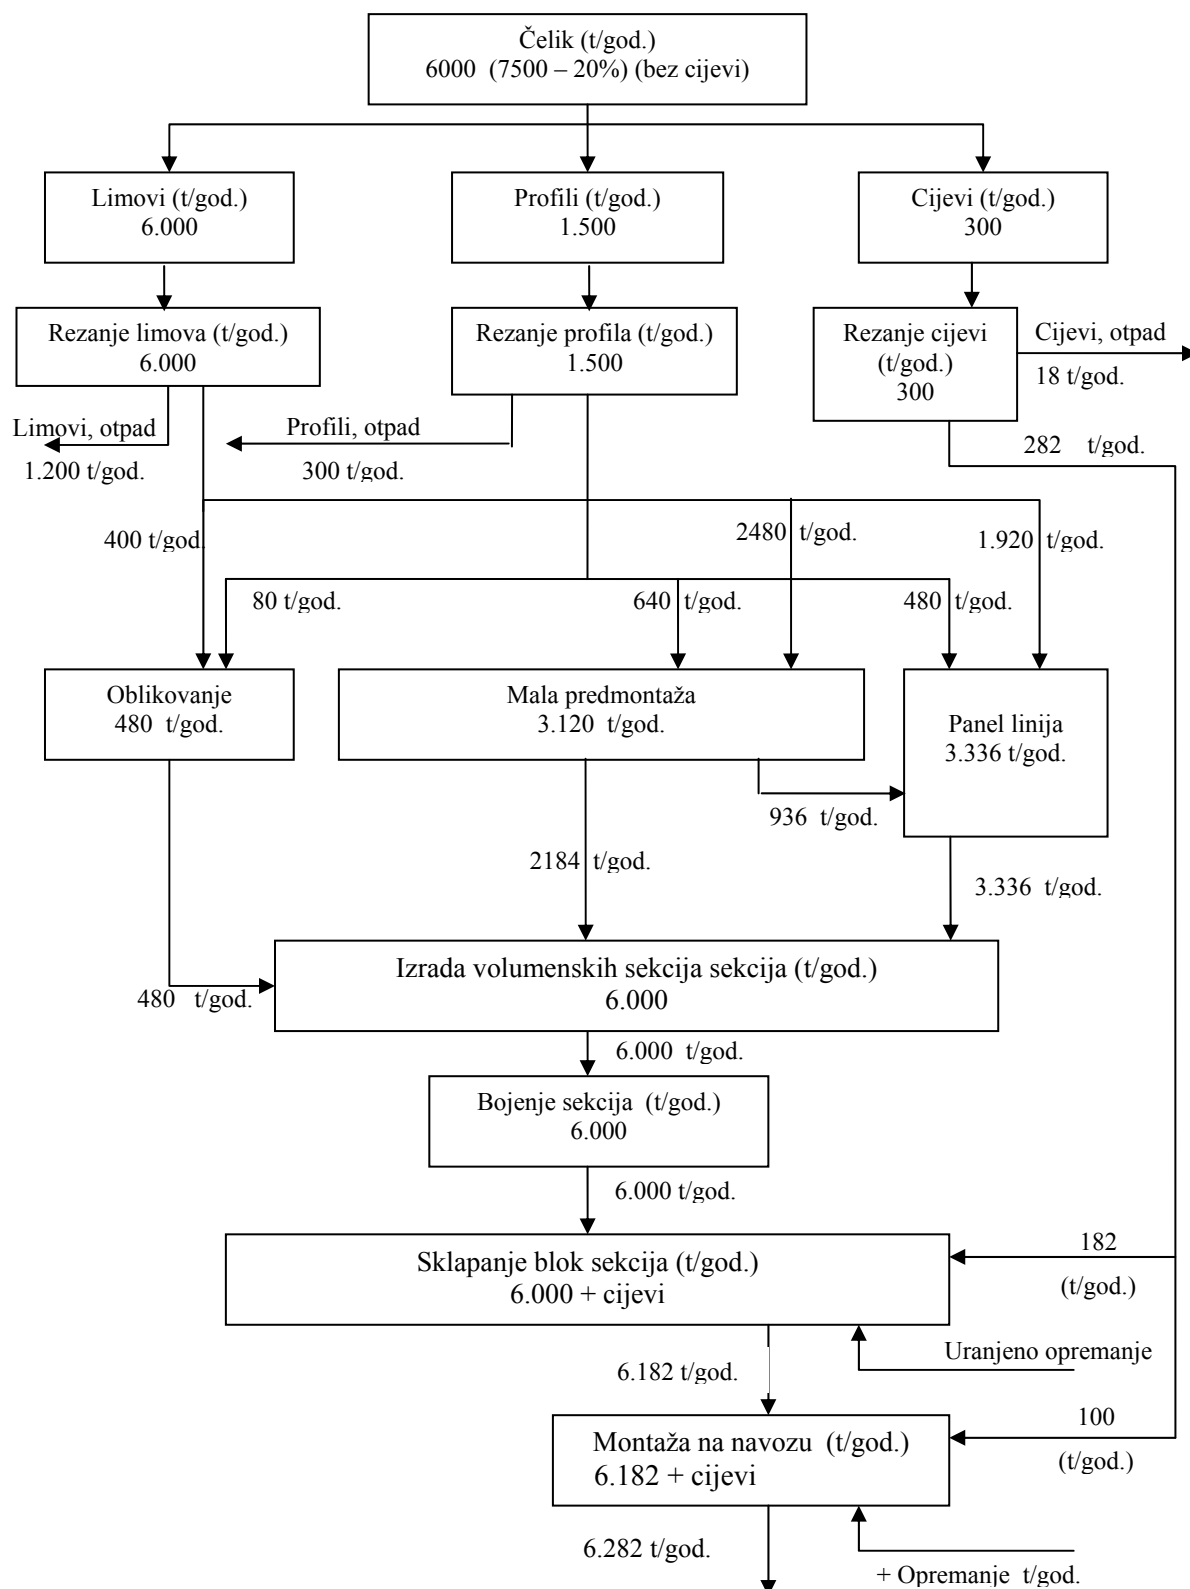
Tablica 5.1.3. Zahtijevani proizvodni program promatranog brodogradilišta, varijanta C

Proizvod	Broj /god.	Netto masa čelika/objekt (t)	Ukupna netto masa čelika (t/god.)	Dužina (m)	Širina (m)	Visina (m)
Brod za prijevoz automobila	2	2000	4000	125	20	15,7
Brod za prijevoz automobila 1	1	1100	1100	87	17,5	3,7
Brod za prijevoz automobila 2	1	900	900	87	17,5	3,7
UKUPNO NOVOGRADNJE			6000			
UKUPNO Č, BRUTO (20%)			7500			
<i>Specijalni plovni objekti (Al): Pilotski brod, jahta, trajekt, patrolni brod, katamaran, nadgrađa, te remont.</i>			25 t aluminija			

Tablica 5.1.4. Ulazni podaci o radnim površinama

Red. br.	Radna stanica	Kratica	Površina, m²
1	Glavno skladište čeličnog materijala	SKL	3520
2	Radionica za rezanje i oblikovanje limova	ROL	1479
3	Radionica za rezanje i oblikovanje profila	ROP	1360
4	Radionica za rezanje limova	RRL	2232
5	Radionica za izradu panela + mala predmontaža	PAN	4480
6	Radionica predmontaže	RPM	3520
7	Radionica za zrnčenje i bojenje gotovih sekcija	ZIB	540
8	Radionica za rezanje i oblikovanje cijevi	RIC	1330
9	Radionica s odjeljenjima za bravare i limare	BIL	915
10	Opremna obala i ostale opremne radionice	MOT	334
11	Radionica za zrnčenje i bojenje opreme	ZBO	300
12	Površina za odlaganje/ukrupnjivanje sekcija	OD1	784
13	Površina za odlaganje gotovih sekcija	OD2	1920
14	Površine za gradnju i predaju broda vodi	NAV	9350
15	Površina mora na prostoru brodogradilišta	SEA	10000

Ukupna površina: 42064 m²



Slika 5.1.2. Shematski prikaz osnovnog brodograđevnog proizvodnog procesa

Nakon analize navedenih ulaznih podataka pristupilo se je provjeri predložene metodologije sljedeći prethodno opisanu proceduru. U prvoj fazi, za utvrđivanje pokazatelja međusobnih odnosa bliskosti i pripadajućih težinskih faktora navedenih proizvodnih površina

koristili rezultati proizašli metodom anketiranja relevantnih eksperata. Prilikom provođenja metode anketiranja eksperti su vodili računa o tehnoložnosti gradnje broda, te optimalnim proizvodnim tokovima osnovnog brodograđevnog procesa.

Nadalje, obradom navedenih rezultata, Prilog 1, određeni su pokazatelji odnosa bliskosti te pripadajući težinski faktori, koji će u sljedećoj fazi, odnosno pri generiranju svih mogućih projektnih rješenja, favorizirati ona rješenja rasporeda proizvodnih površina koja teže optimalnim proizvodnim tokovima brodograđevnog procesa, a na temelju *SLP* ocjene rasporeda površina. Pokazatelji odnosa bliskosti odabranih proizvodnih površina prikazani se u matrici odnosa bliskosti, tablica 5.1.3. Pripadajući težinski faktori pojedinih oznaka bliskosti dani su u tablici 5.1.4.

Tablica 5.1.3. Matrica odnosa bliskosti

		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
		<i>SKL</i>	<i>ROL</i>	<i>ROP</i>	<i>RRL</i>	<i>PAN</i>	<i>RPM</i>	<i>ZIB</i>	<i>RIC</i>	<i>BIL</i>	<i>MOT</i>	<i>ZBO</i>	<i>OD1</i>	<i>OD2</i>	<i>NAV</i>	<i>SEA</i>
1	<i>SKL</i>	◇	<i>A</i>	<i>A</i>	<i>A</i>	<i>O</i>	<i>O</i>	<i>U</i>	<i>E</i>	<i>O</i>	<i>O</i>	<i>O</i>	<i>U</i>	<i>U</i>	<i>U</i>	<i>I</i>
2	<i>ROL</i>	<i>A</i>	◇	<i>I</i>	<i>I</i>	<i>I</i>	<i>E</i>	<i>U</i>	<i>U</i>	<i>U</i>	<i>U</i>	<i>U</i>	<i>O</i>	<i>U</i>	<i>O</i>	<i>U</i>
3	<i>ROP</i>	<i>A</i>	<i>I</i>	◇	<i>I</i>	<i>E</i>	<i>E</i>	<i>U</i>	<i>U</i>	<i>O</i>	<i>U</i>	<i>U</i>	<i>O</i>	<i>U</i>	<i>U</i>	<i>U</i>
4	<i>RRL</i>	<i>A</i>	<i>I</i>	<i>I</i>	◇	<i>A</i>	<i>E</i>	<i>U</i>	<i>U</i>	<i>O</i>	<i>U</i>	<i>U</i>	<i>O</i>	<i>U</i>	<i>O</i>	<i>U</i>
5	<i>PAN</i>	<i>O</i>	<i>I</i>	<i>E</i>	<i>A</i>	◇	<i>A</i>	<i>I</i>	<i>U</i>	<i>O</i>	<i>U</i>	<i>U</i>	<i>I</i>	<i>O</i>	<i>O</i>	<i>U</i>
6	<i>RPM</i>	<i>O</i>	<i>E</i>	<i>E</i>	<i>E</i>	<i>A</i>	◇	<i>A</i>	<i>I</i>	<i>I</i>	<i>I</i>	<i>O</i>	<i>E</i>	<i>E</i>	<i>I</i>	<i>O</i>
7	<i>ZIB</i>	<i>U</i>	<i>U</i>	<i>U</i>	<i>U</i>	<i>I</i>	<i>A</i>	◇	<i>U</i>	<i>U</i>	<i>O</i>	<i>O</i>	<i>E</i>	<i>E</i>	<i>E</i>	<i>U</i>
8	<i>RIC</i>	<i>E</i>	<i>U</i>	<i>U</i>	<i>U</i>	<i>U</i>	<i>I</i>	<i>U</i>	◇	<i>I</i>	<i>E</i>	<i>E</i>	<i>I</i>	<i>I</i>	<i>I</i>	<i>I</i>
9	<i>BIL</i>	<i>O</i>	<i>U</i>	<i>O</i>	<i>O</i>	<i>O</i>	<i>I</i>	<i>U</i>	<i>I</i>	◇	<i>E</i>	<i>E</i>	<i>I</i>	<i>O</i>	<i>I</i>	<i>O</i>
10	<i>MOT</i>	<i>O</i>	<i>U</i>	<i>U</i>	<i>U</i>	<i>U</i>	<i>I</i>	<i>O</i>	<i>E</i>	<i>E</i>	◇	<i>I</i>	<i>I</i>	<i>O</i>	<i>I</i>	<i>E</i>
11	<i>ZBO</i>	<i>O</i>	<i>U</i>	<i>U</i>	<i>U</i>	<i>U</i>	<i>O</i>	<i>O</i>	<i>E</i>	<i>E</i>	<i>I</i>	◇	<i>I</i>	<i>I</i>	<i>I</i>	<i>U</i>
12	<i>OD1</i>	<i>U</i>	<i>O</i>	<i>I</i>	<i>O</i>	<i>I</i>	<i>E</i>	<i>E</i>	<i>I</i>	<i>I</i>	<i>I</i>	<i>I</i>	◇	<i>I</i>	<i>A</i>	<i>O</i>
13	<i>OD2</i>	<i>U</i>	<i>U</i>	<i>U</i>	<i>U</i>	<i>O</i>	<i>E</i>	<i>E</i>	<i>I</i>	<i>O</i>	<i>O</i>	<i>I</i>	<i>I</i>	◇	<i>E</i>	<i>O</i>
14	<i>NAV</i>	<i>U</i>	<i>O</i>	<i>U</i>	<i>O</i>	<i>O</i>	<i>I</i>	<i>E</i>	<i>I</i>	<i>I</i>	<i>I</i>	<i>I</i>	<i>A</i>	<i>E</i>	◇	<i>A</i>
15	<i>SEA</i>	<i>I</i>	<i>U</i>	<i>U</i>	<i>U</i>	<i>U</i>	<i>O</i>	<i>U</i>	<i>I</i>	<i>O</i>	<i>E</i>	<i>U</i>	<i>O</i>	<i>O</i>	<i>A</i>	◇

Tablica 5.1.4. Težinski faktori oznaka bliskosti

Oznaka bliskosti	Bliskost	Težinski faktor
<i>A</i>	Isključivo potrebna	45
<i>E</i>	Potrebna	11
<i>I</i>	Važna	3
<i>O</i>	Neznatno važna	1
<i>U</i>	Nevažna	0
<i>X</i>	Nepoželjna	-45

5.2 FAZA 2 – Generiranje mogućih rješenja rasporeda proizvodnih površina postojećeg brodogradilišta korištenjem SLP metode te odabir najizglednijih temeljem utvrđenih odnosa bliskosti

Kako je i predloženo u samom opisu metodologije, u drugoj fazi izvršeno je generiranje svih teoretski mogućih varijanti rasporeda proizvodnih površina postojećeg brodogradilišta korištenjem SLP metode. Odnosi bliskosti, utvrđeni u prvoj fazi, korišteni su unutar SLP metode za izračun ocjene pojedinih generiranih varijanti rasporeda proizvodnih površina. Primjenom sistematskog planiranja rasporeda površina kroz specijalizirani računalni program [114] automatski se vršio smještaj odabranih površina iz tablice 5.1.2. na sve moguće načine u definirani prostor, kreirajući tako 1.3×10^{12} varijanti. Jedino ograničenje koje se nametnulo u definiranom prostoru jest fiksna pozicija mora i navoza.

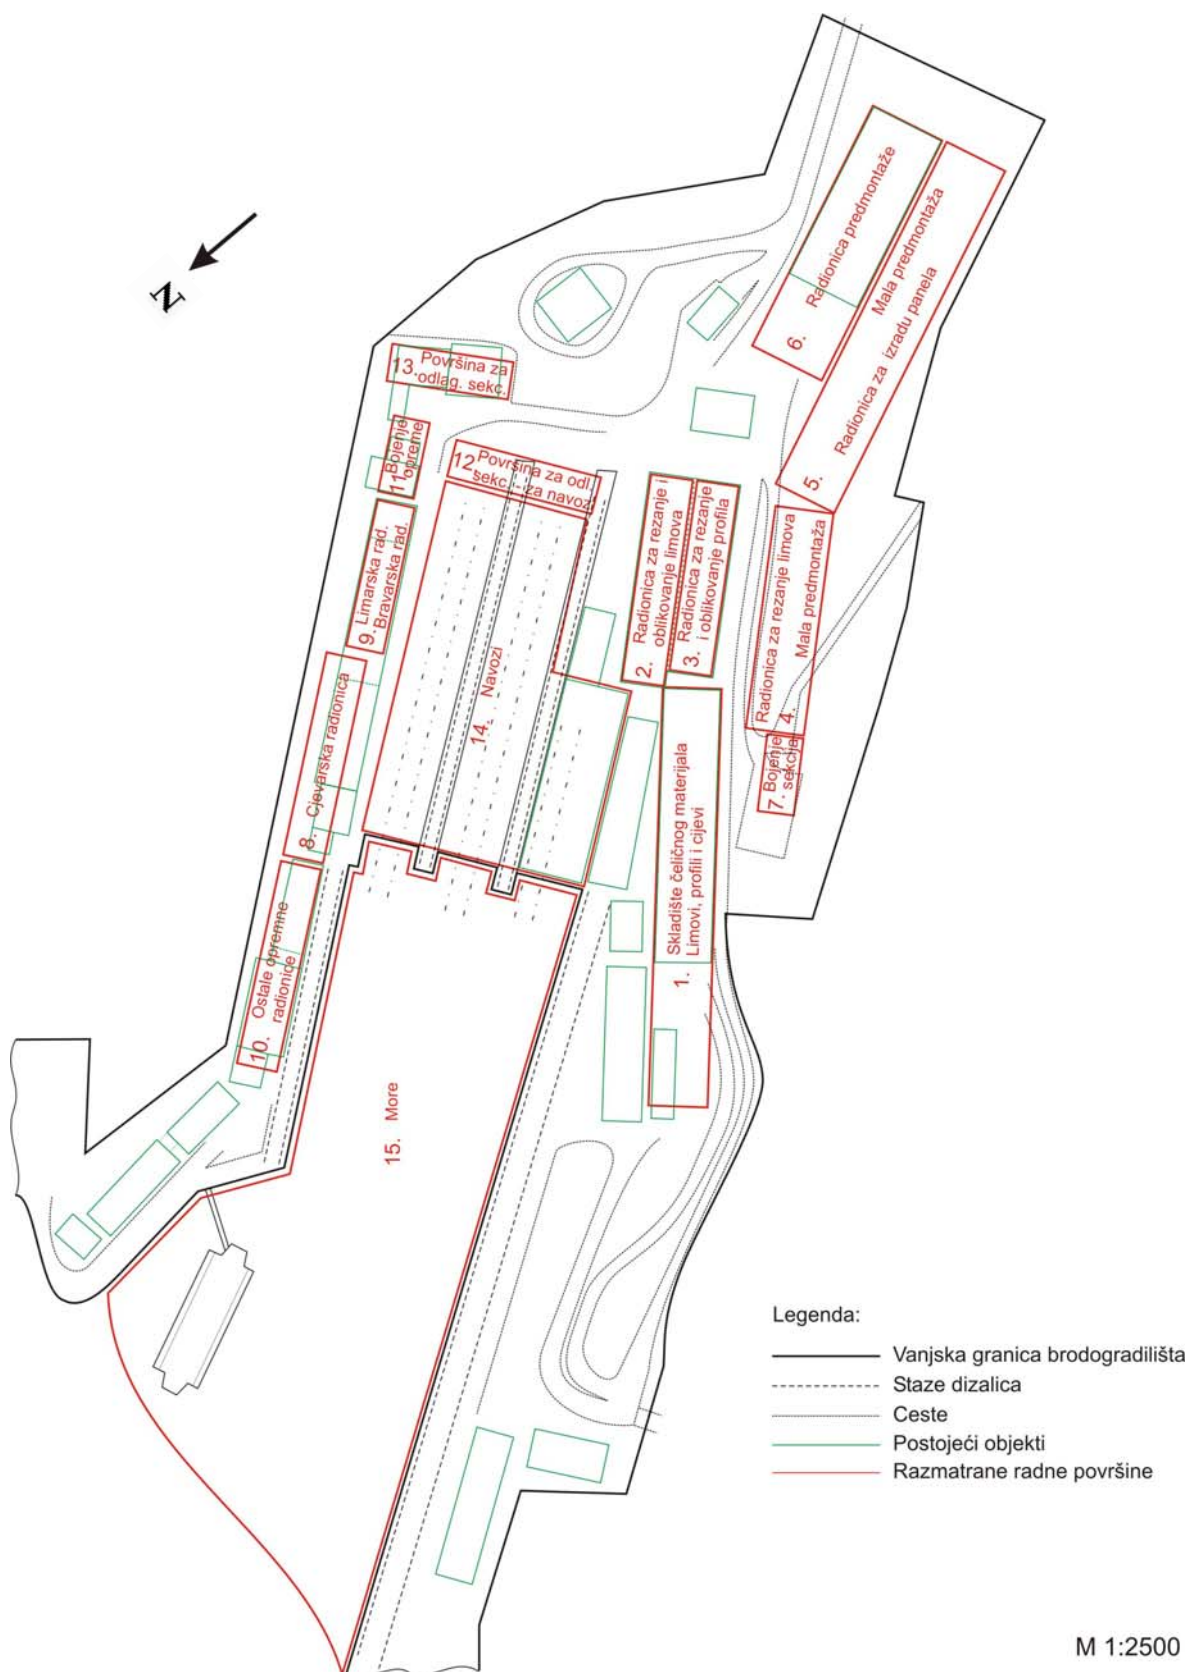
Nadalje, prema izrazu (2), za svaku je varijantu izračunata SLP ocjena rasporeda površina. Na taj način utvrđeno je dvadeset najizglednijih varijanti rasporeda proizvodnih površina koje su odabrane za daljnje razmatranje, Prilog 2. Izračunate SLP ocjene prikazane su u normaliziranom obliku u tablici 5.2.1.

Tablica 5.2.1. SLP ocjene rasporeda površina najizglednijih varijanti

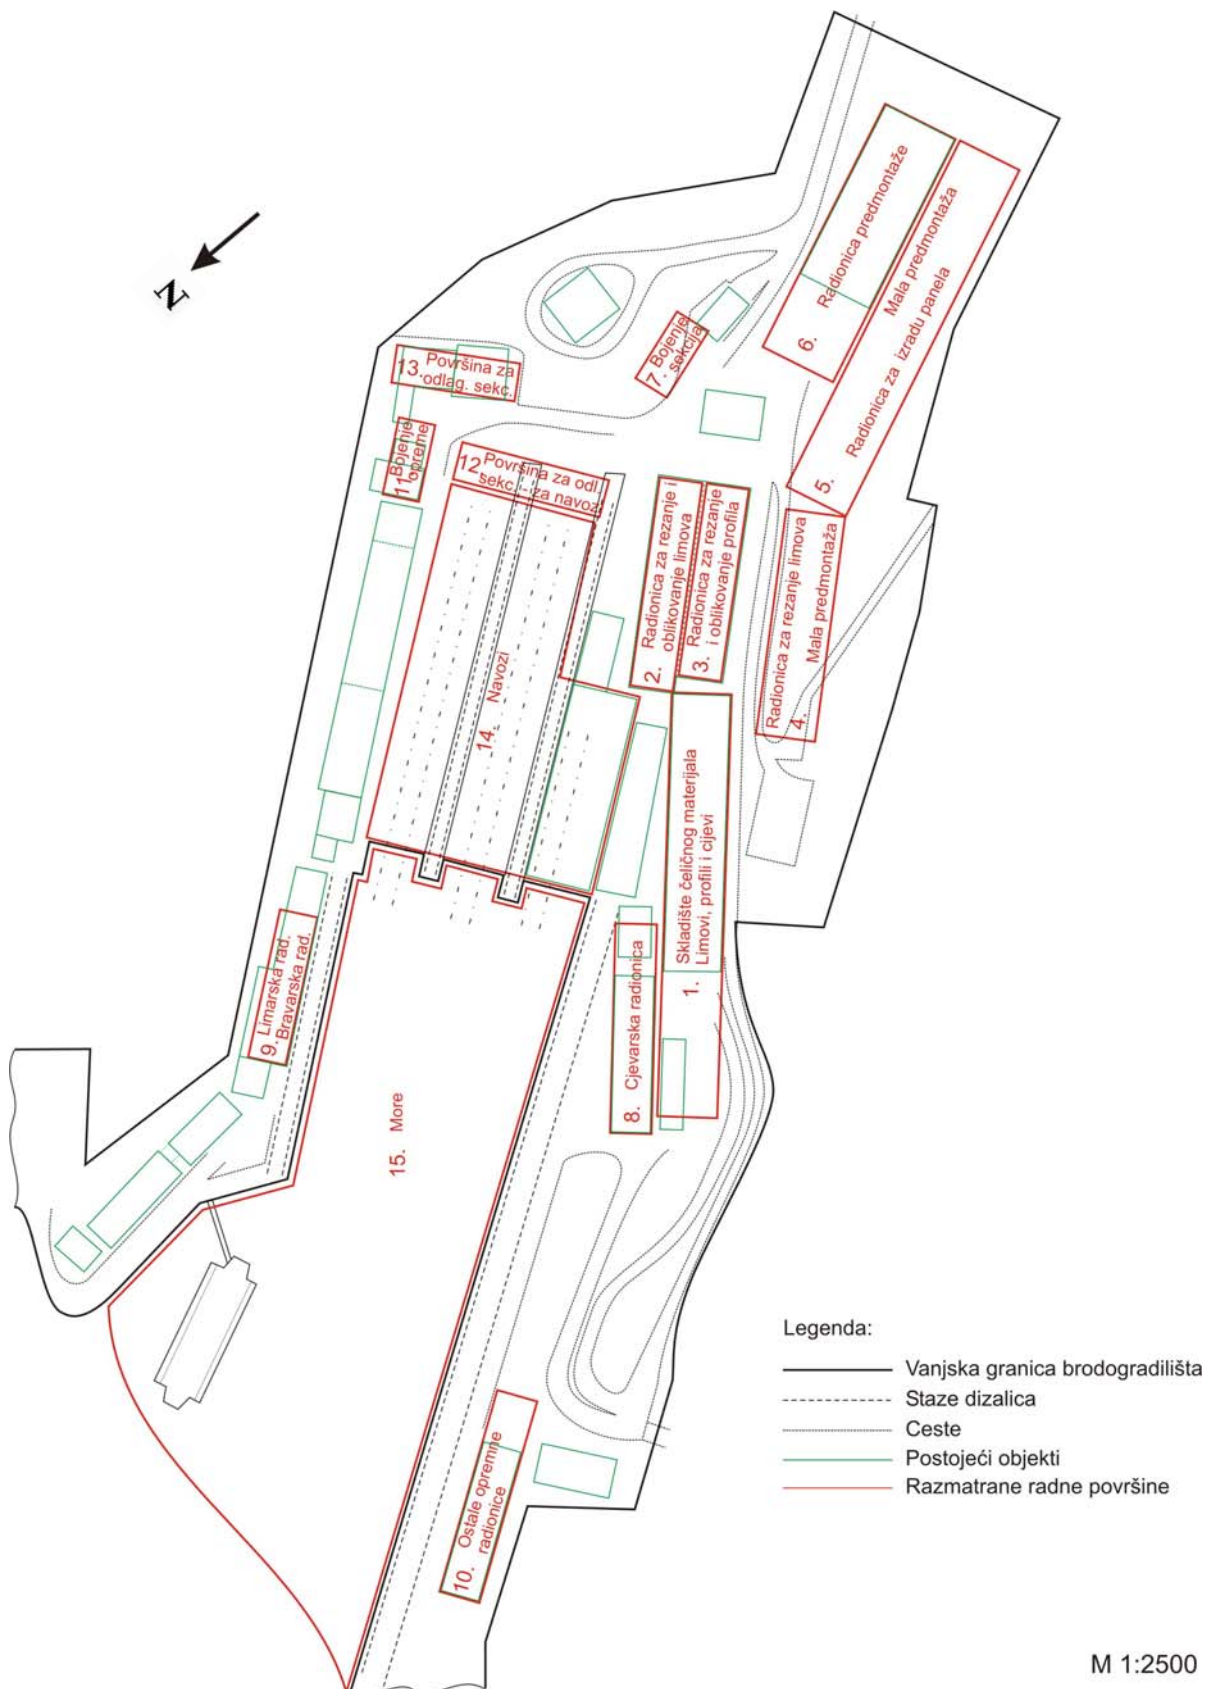
Varijanta br:	1	2	3	4	5	6	7	8	9	10
Ocjena:	0,66	0,71	0,54	0,68	0,73	0,6	0,58	0,7	0,69	0,58

Varijanta br:	11	12	13	14	15	16	17	18	19	20
Ocjena:	0,65	0,76	0,71	0,6	0,71	0,67	0,69	0,73	0,57	0,73

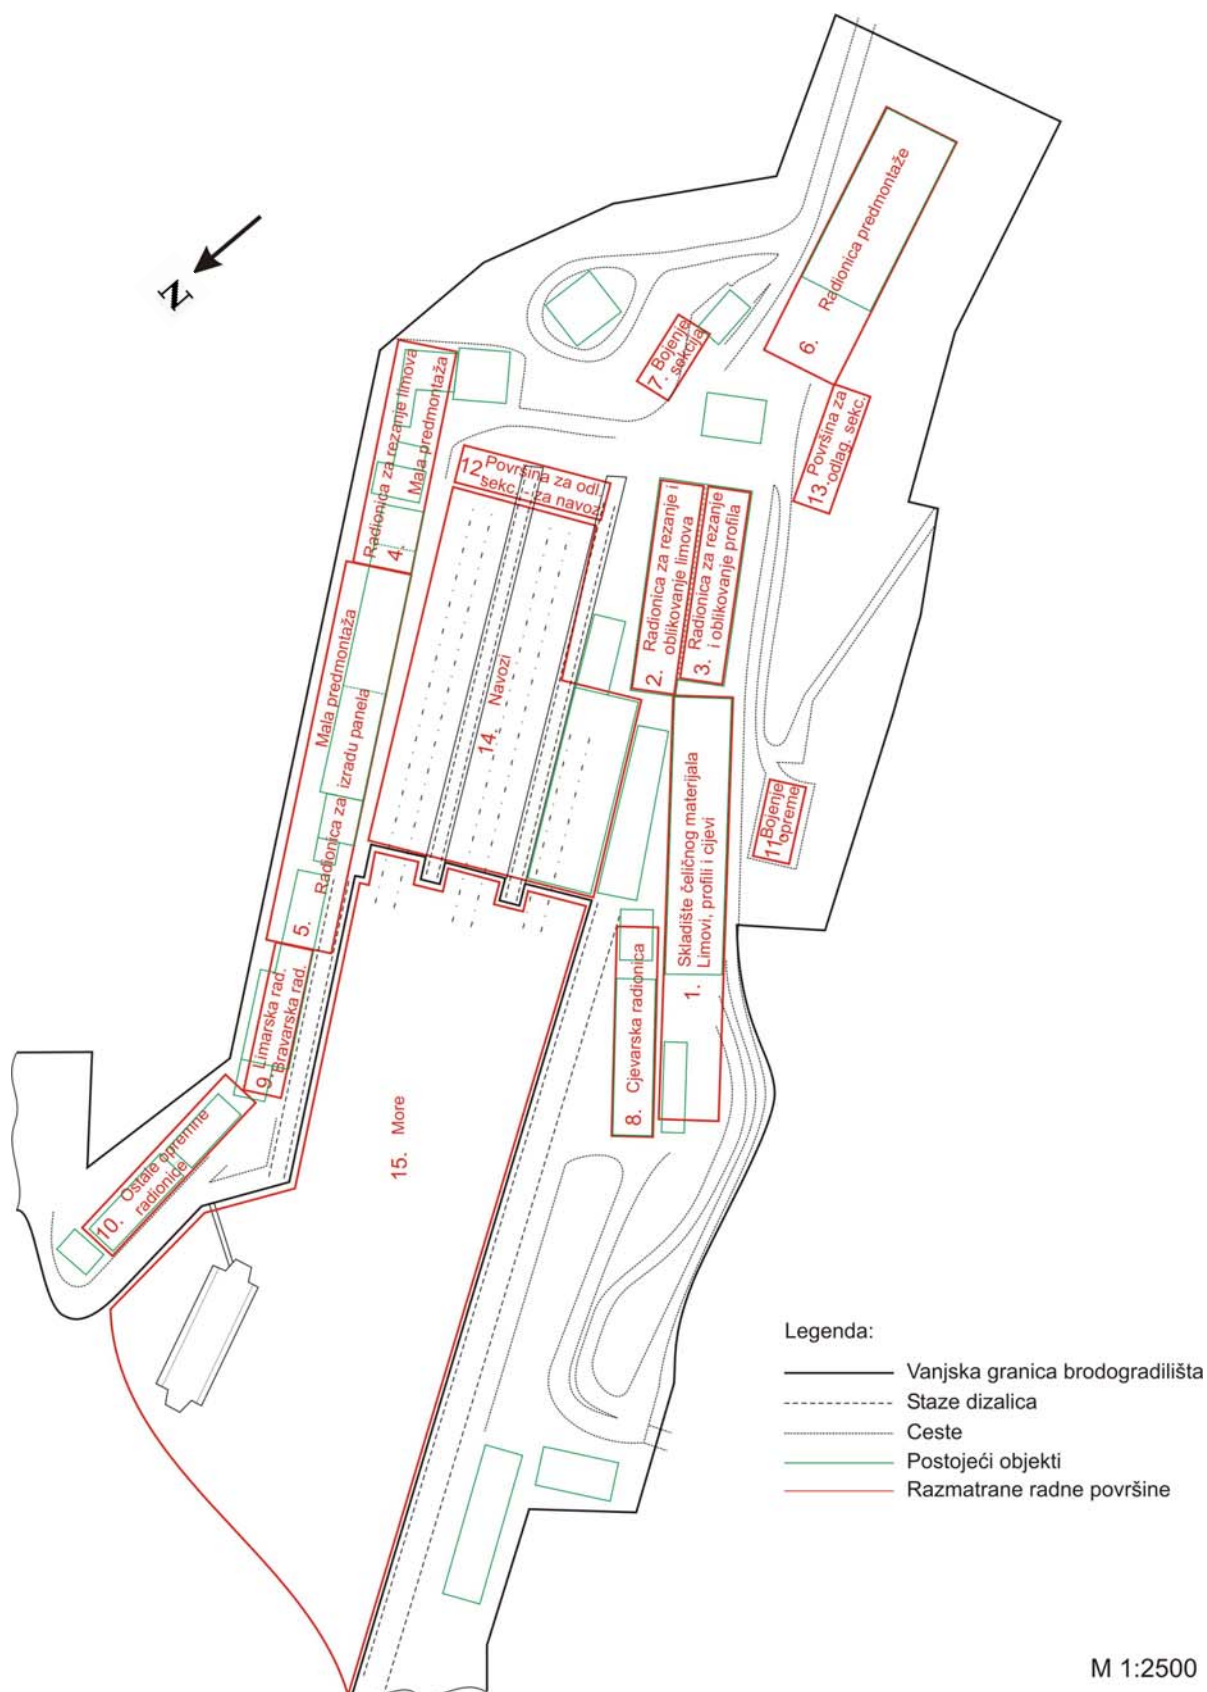
Rezultati, odnosno prikazi odabranih varijanti dani su na pravokutnikom aproksimiranom tlocrtu brodogradilišta, kako je vidljivo u Prilogu 2, slike P2.4, P2.5, P2.6, P2.7 i P2.8. Rezultati računalnog programa prevedeni su u realni tlocrt brodogradilišta s realnim omjerima proizvodnih površina. Navedenih 20 najizglednijih varijanti, koje se uzimaju u razmatranje kroz treću fazu, prikazano je tlocrtno na ljeđećim slikama, os 5.2.1 do 5.2.20.



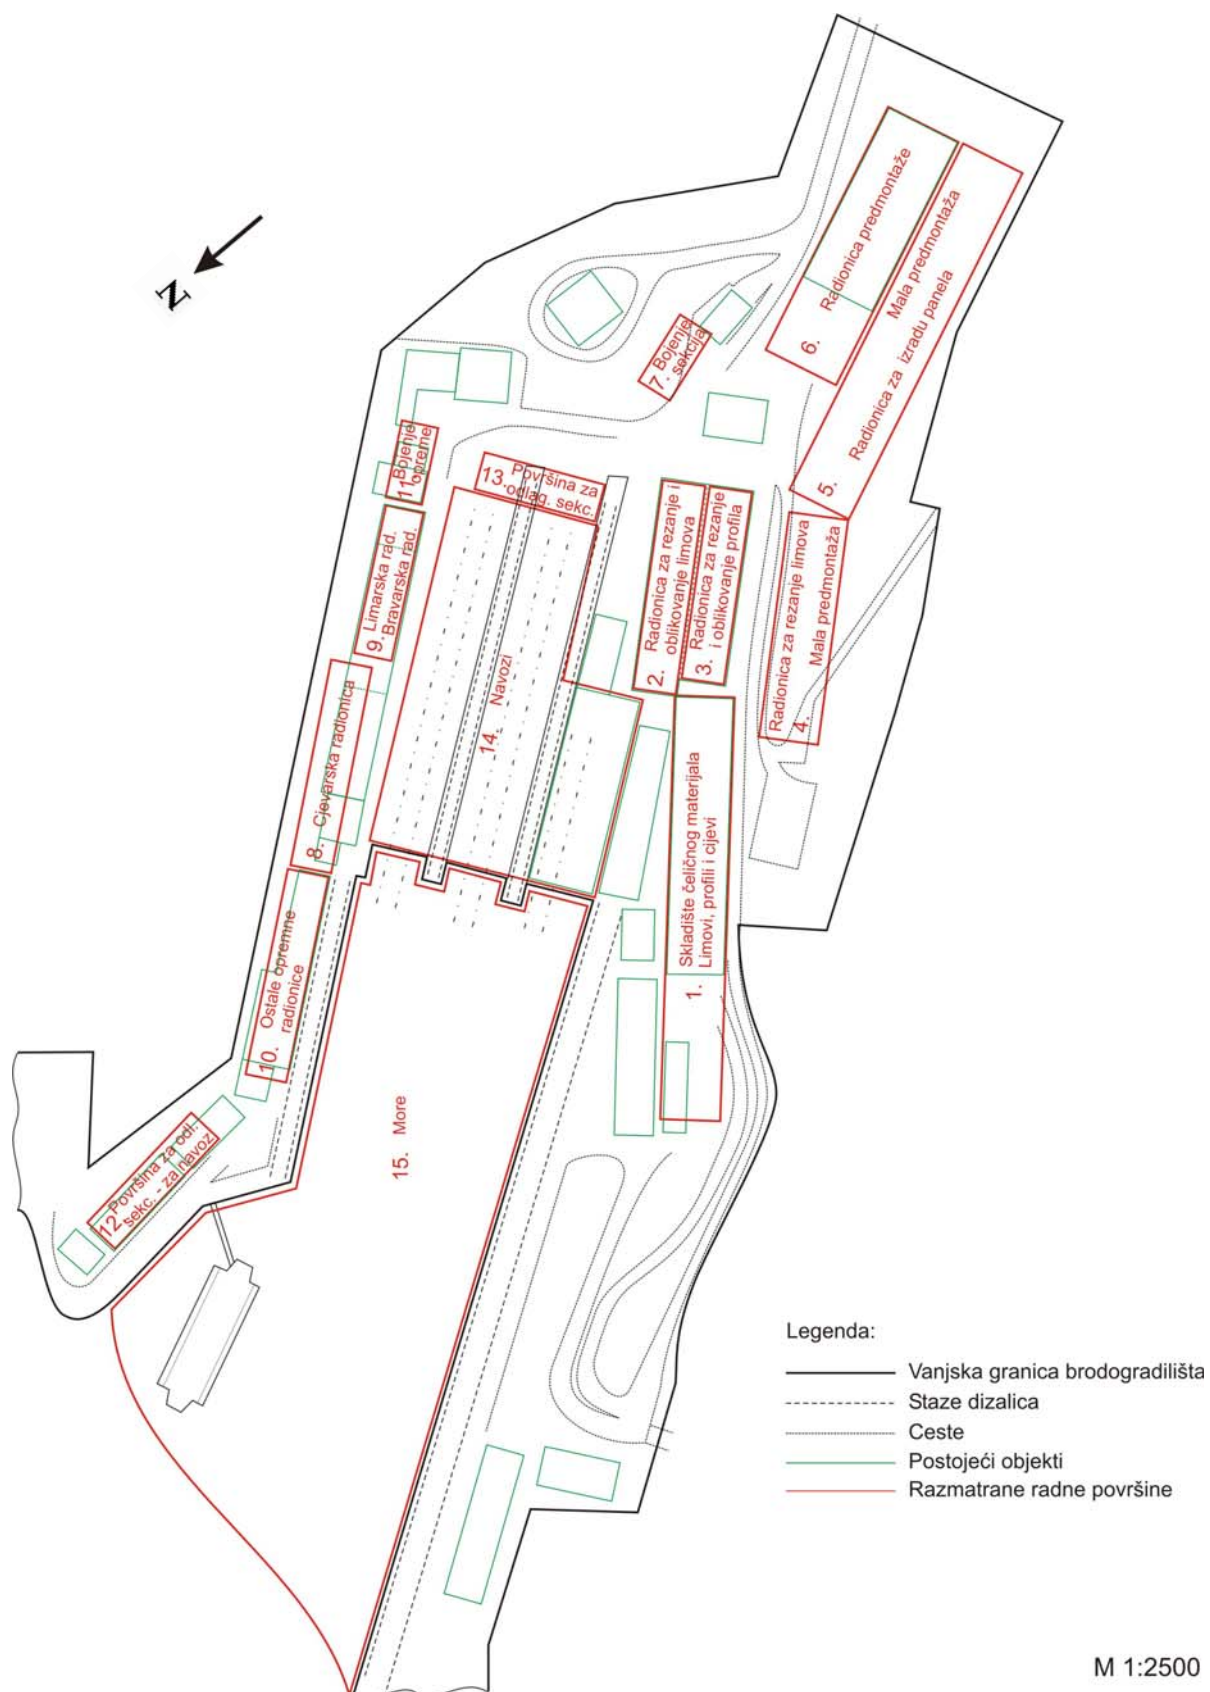
Slika 5.2.1. Prikaz varijante 1 generirane SLP metodom



Slika 5.2.2. Prikaz varijante 2 generirane SLP metodom

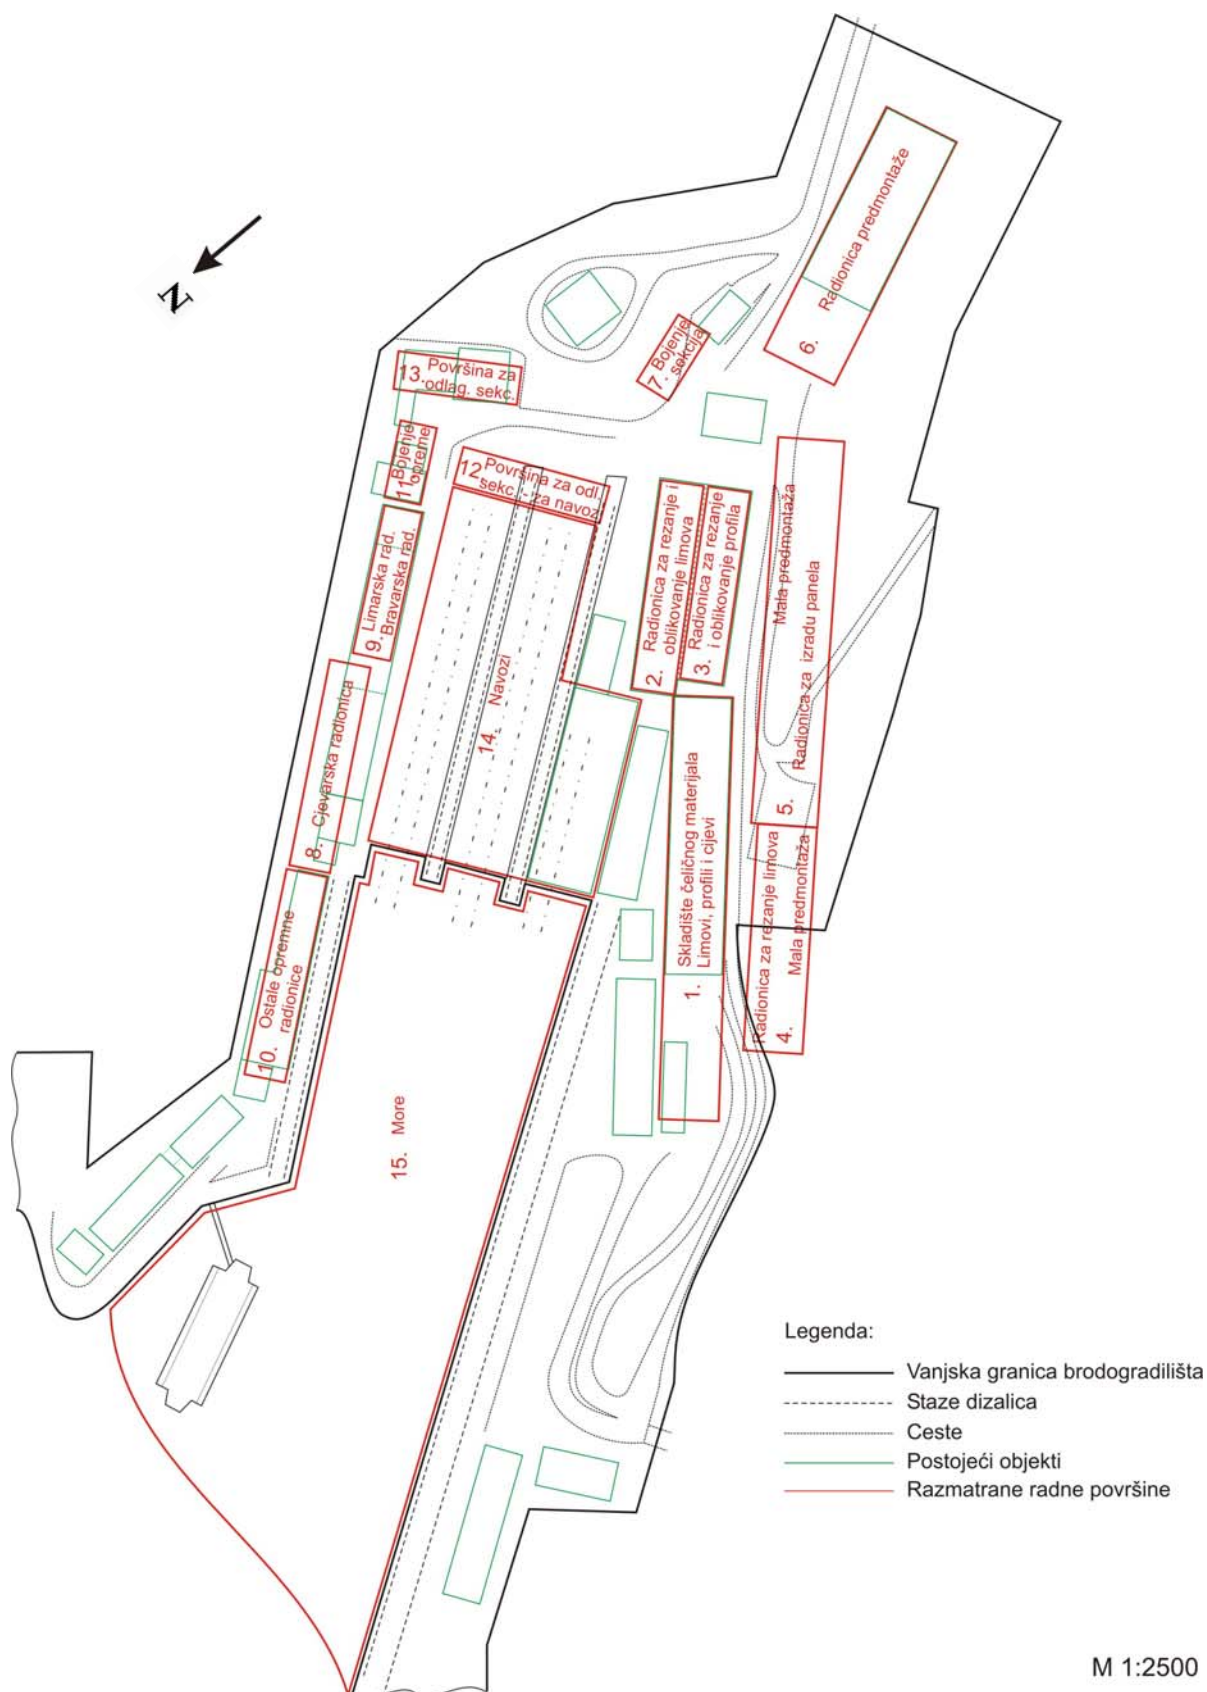


Slika 5.2.3. Prikaz varijante 3 generirane SLP metodom



M 1:2500

Slika 5.2.4. Prikaz varijante 4 generirane SLP metodom



Slika 5.2.5. Prikaz varijante 5 generirane SLP metodom

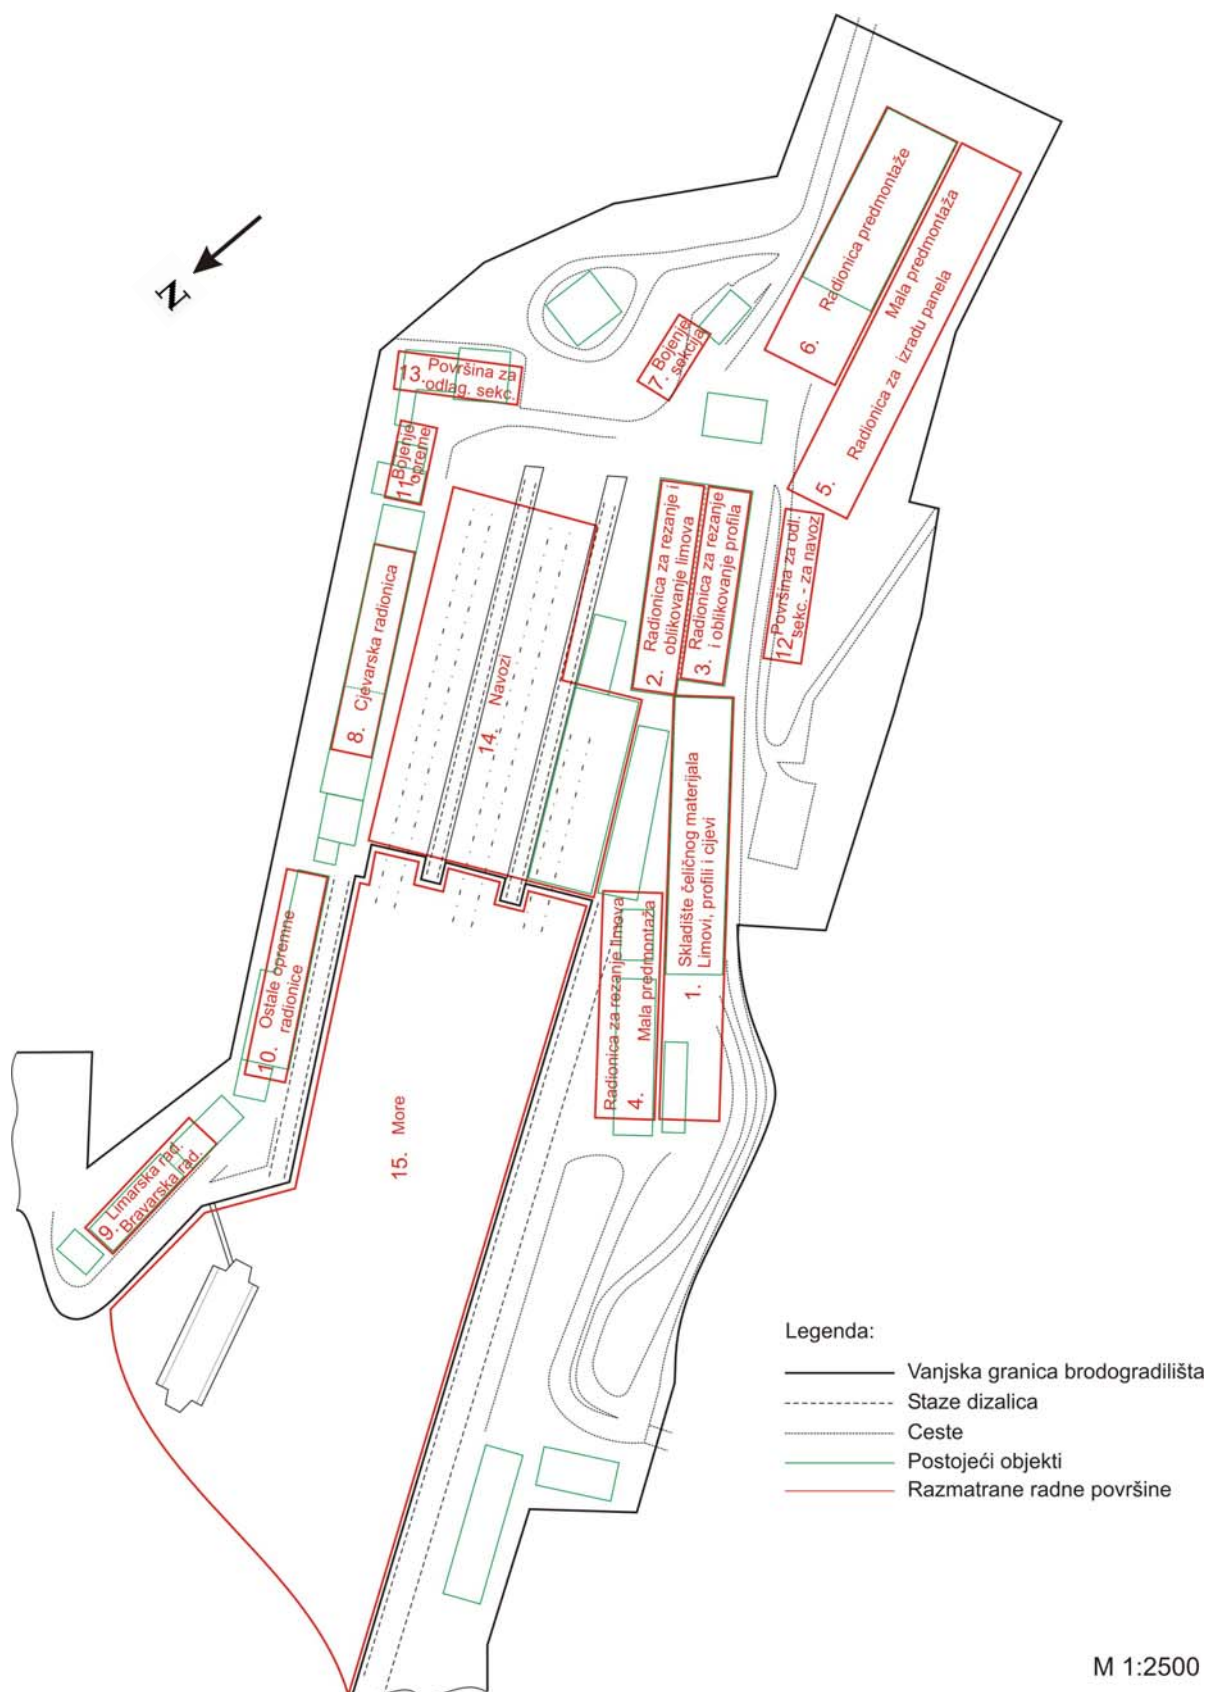
Varijanta 1, prikazana na slici 5.2.1., odabrana je s *SLP* ocjenom rasporeda površina od 0,66. Navedena ocjena govori da promatrana varijanta zadovoljava saznanja o optimalnom toku materijala u iznosu od 66%. Karakteristika ove varijante jest ta da su sve radionice predobrade i obrade limova te profila s pripadajućim skladištem, kao i radionice predmontaže smještene s južne strane, dok su opremne radionice smještene sa sjeverne strane brodogradilišta. Detaljnom analizom varijante 1 utvrđeno je da za njenu realizaciju je potrebno rušenje 14 postojećih objekata, te ometati tekuću proizvodnju sa 40%. Procjena investicije kreće se oko 24,3 milijuna eura.

Varijanta 2, prikazana na slici 5.2.2., odabrana je s *SLP* ocjenom rasporeda površina od 0,71. Sa tog stajališta bolja je od prethodne. Nadalje, detaljnom analizom varijante 2 utvrđeno je da za njenu realizaciju je potrebno rušenje samo 7 postojećih objekata, te vrlo malo ometati na tekuću proizvodnju, sa 15%. Procjena investicije kreće se oko 21,1 milijuna eura što je vrlo prihvatljiva cijena. Može se zaključiti da će ova varijanta biti visoko rangirana pri odabiru optimalnog projektnog rješenja.

Varijanta 3, prikazana na slici 5.2.3., odabrana je kao posljednja, dvadeseta, s najnižom *SLP* ocjenom rasporeda površina od 0,54. Razlog tomu leži u izdvojenim radionicama za rezanje limova te izradu panela od samog skladišta kao prethodnog koraka, te radionice predmontaže kao narednog koraka u proizvodnom toku opisanom ocjenama bliskosti. Analizom varijante 3 utvrđeno je da za njenu realizaciju je potrebno rušenje 11 postojećih objekata, te ometati tekuću proizvodnju s iznosom od 55%. Procjena investicije kreće se oko 24,1 milijuna eura.

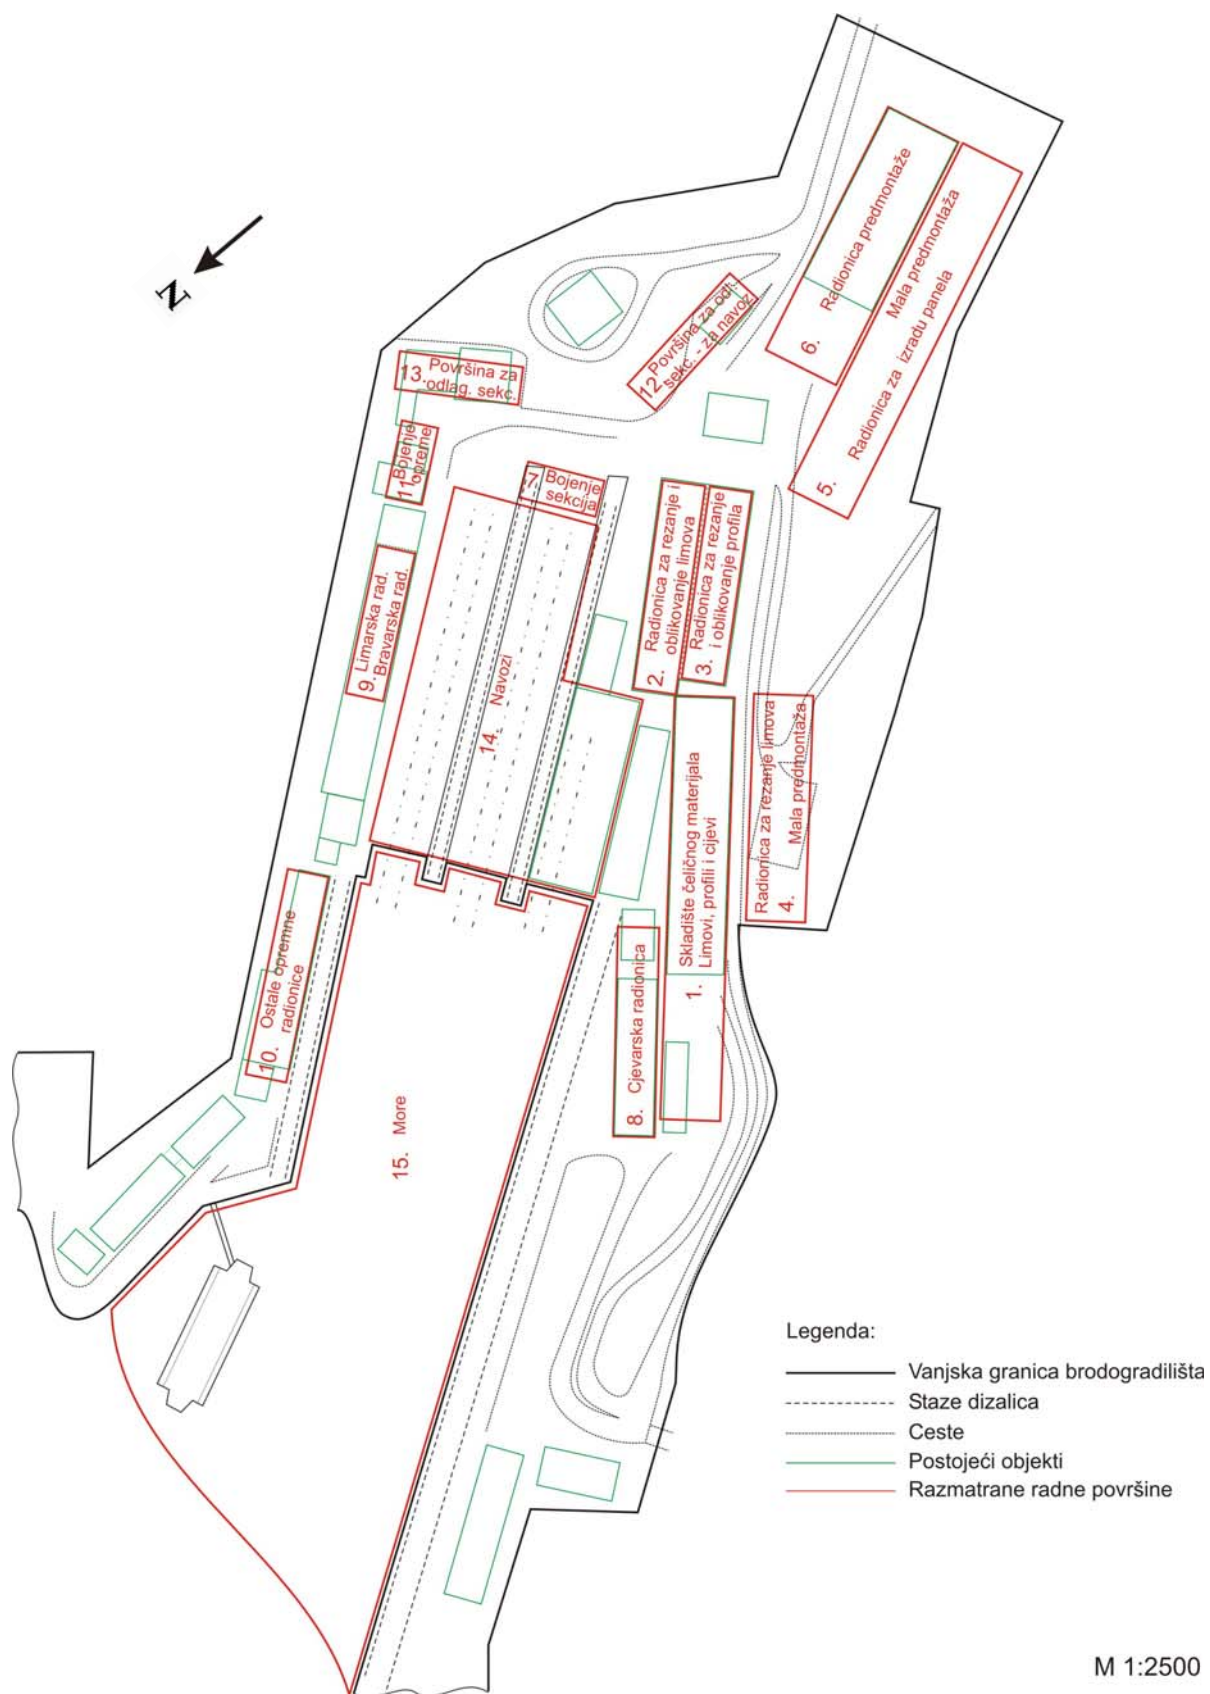
Varijanta 4, prikazana na slici 5.2.4., odabrana je s *SLP* ocjenom rasporeda površina od 0,68. Detaljnom analizom varijante 4 utvrđeno je da za njenu realizaciju je potrebno rušenje 14 postojećih objekata, te ometati tekuću proizvodnju sa 35%. Procjena investicije kreće se oko 24,8 milijuna eura.

Varijanta 5, prikazana na slici 5.2.5., odabrana je s visokom *SLP* ocjenom rasporeda površina od 0,73. Ispunjavanje saznanja o optimalnim proizvodnim tokovima sa visokih 73% zasigurno je svrstavaju u sam vrh mogućih varijanti sa tog stajališta. Međutim velika mana ove varijante jest potreba za širenjem izvan postojećih površina brodogradilišta. Nadalje, daljnjom analizom varijante 5 utvrđeno je da je za njenu realizaciju potrebno rušenje čak 15 postojećih objekata, te ometati tekuću proizvodnju sa 30%. Procjena investicije kreće se oko 24,8 milijuna eura.

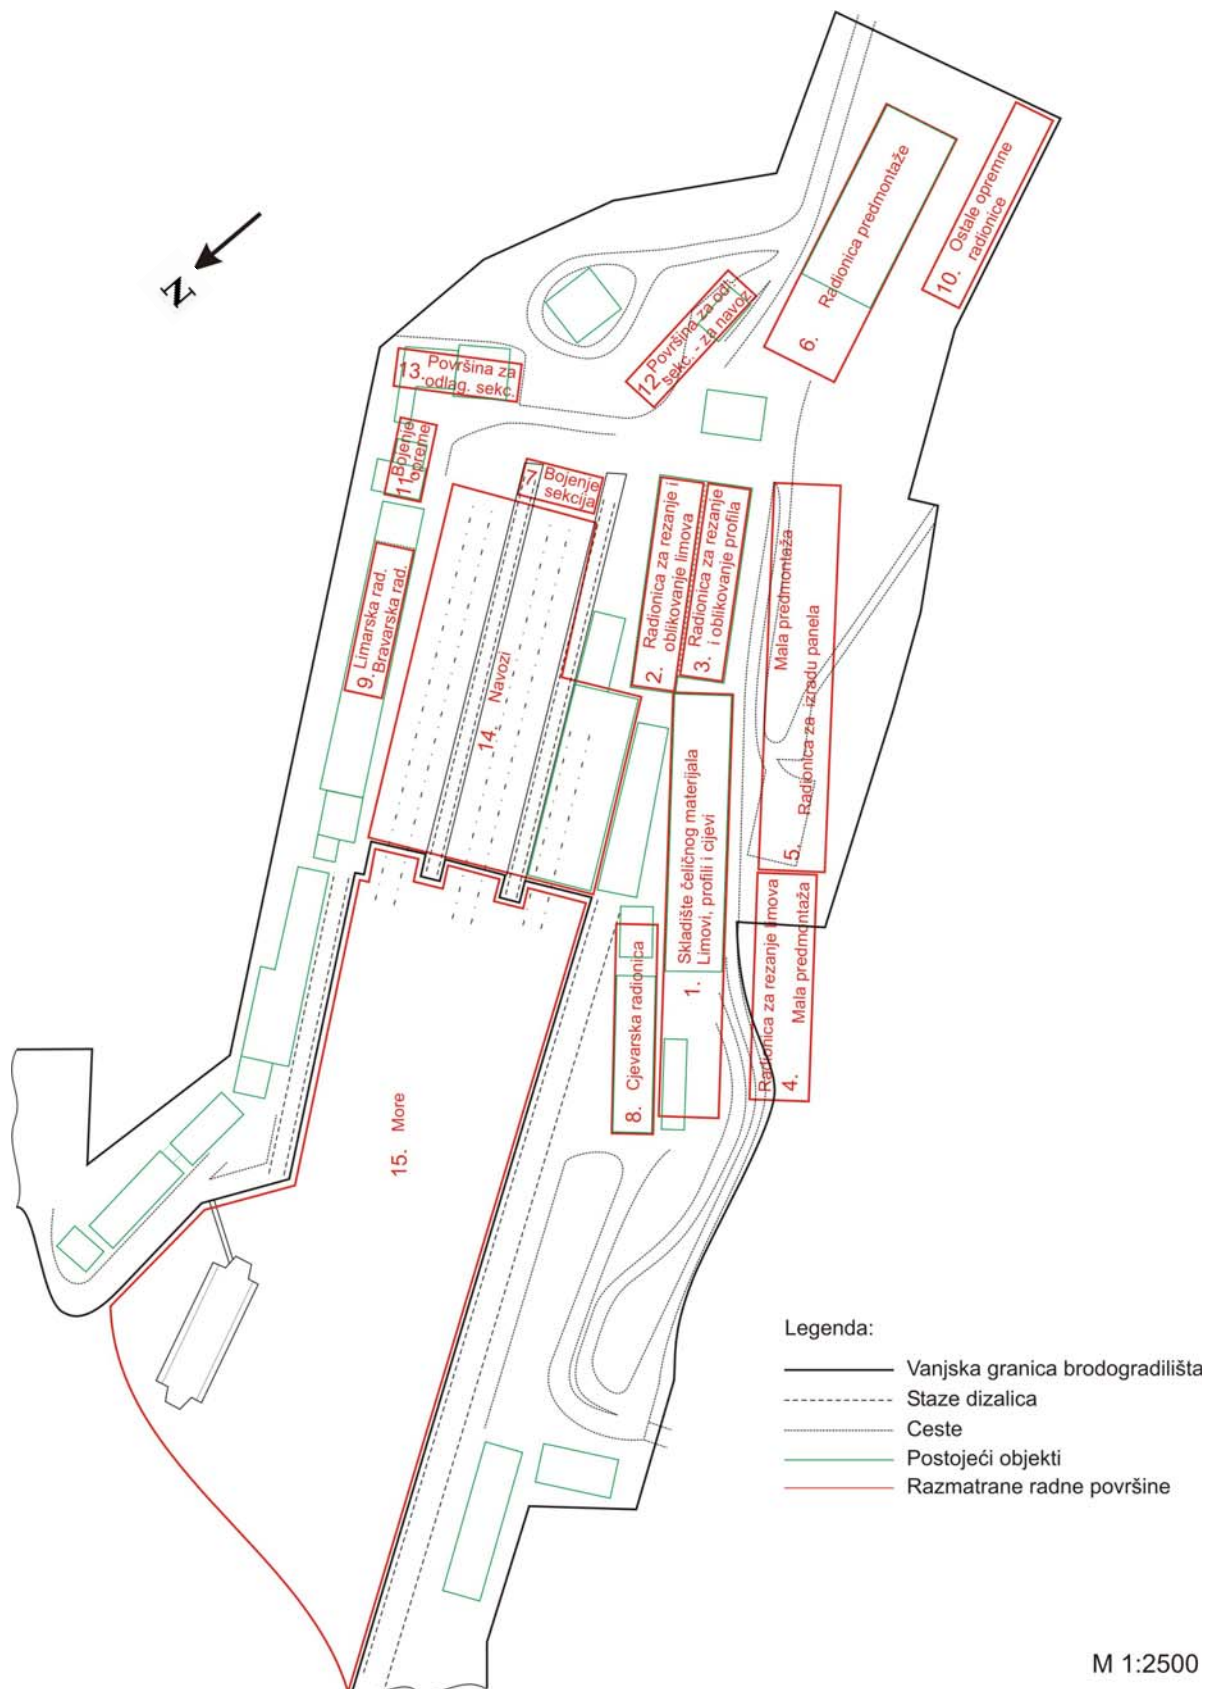


M 1:2500

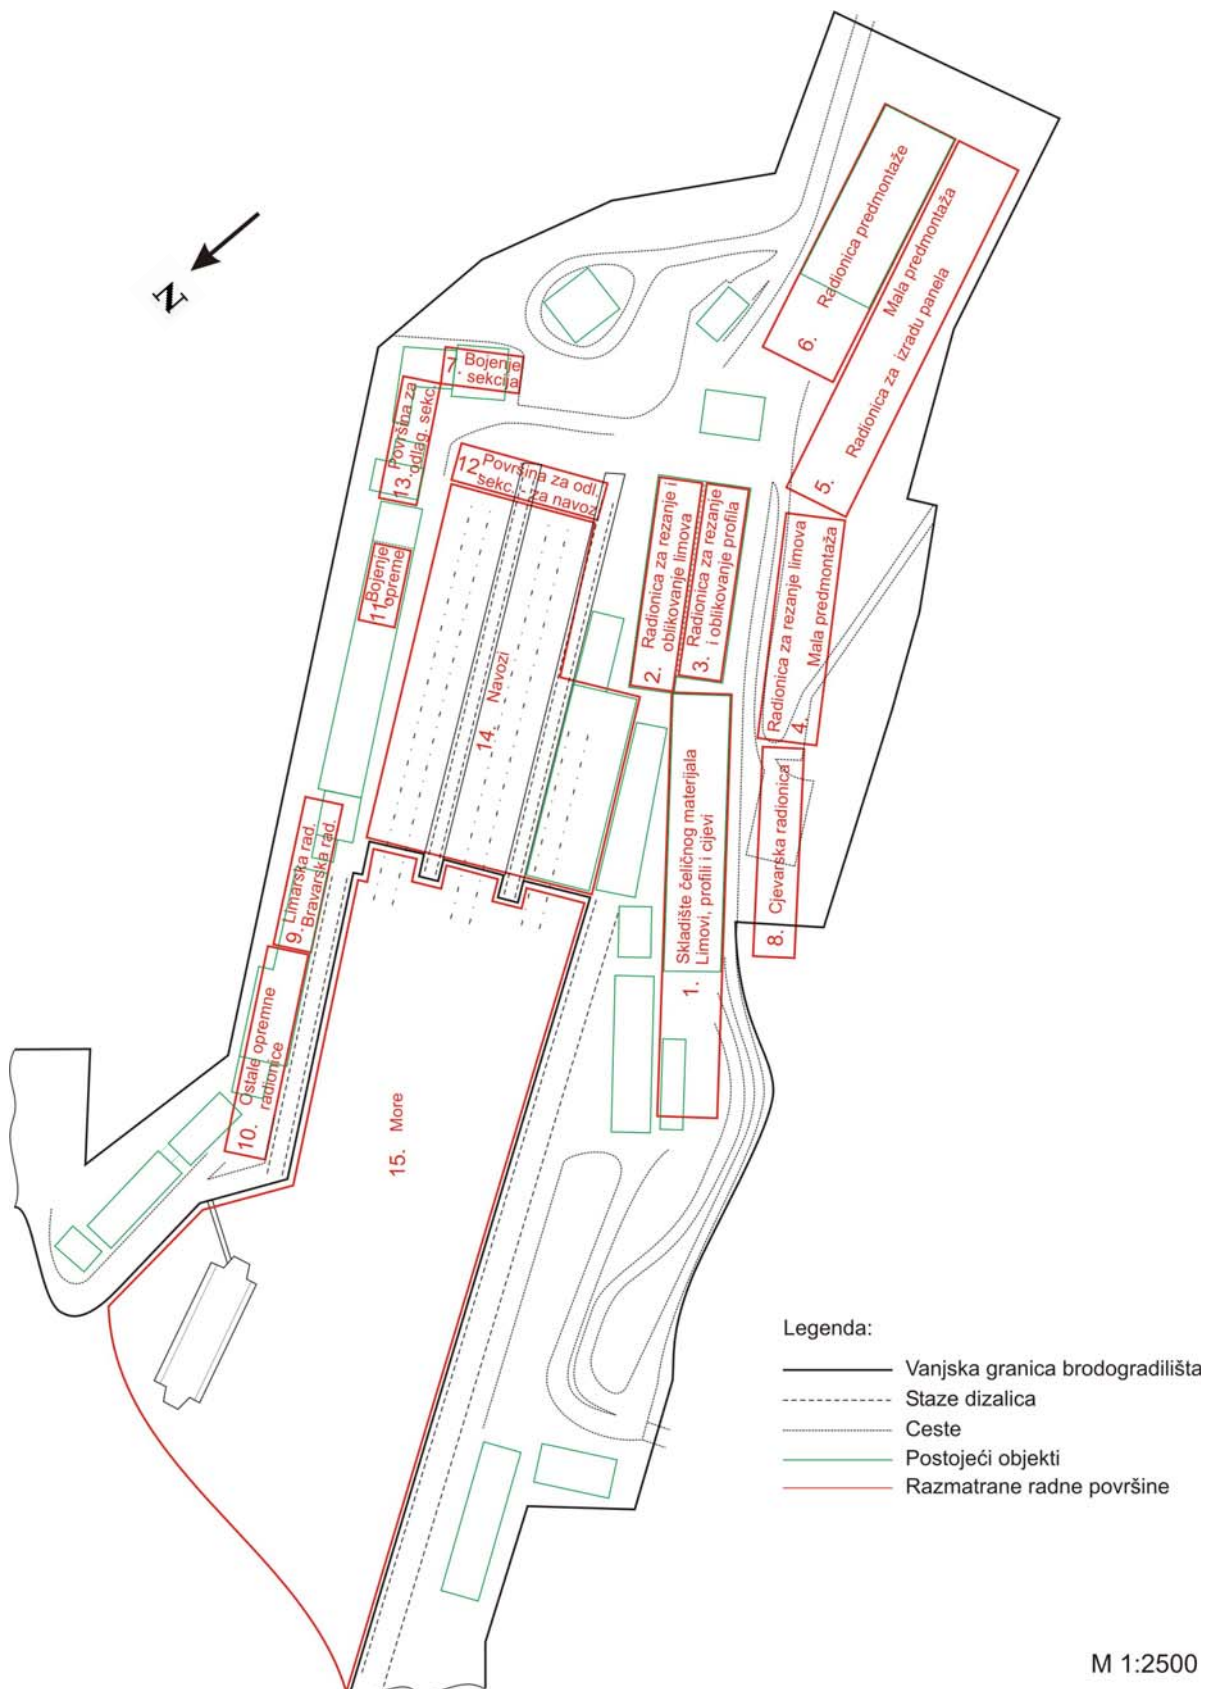
Slika 5.2.6. Prikaz varijante 6 generirane SLP metodom



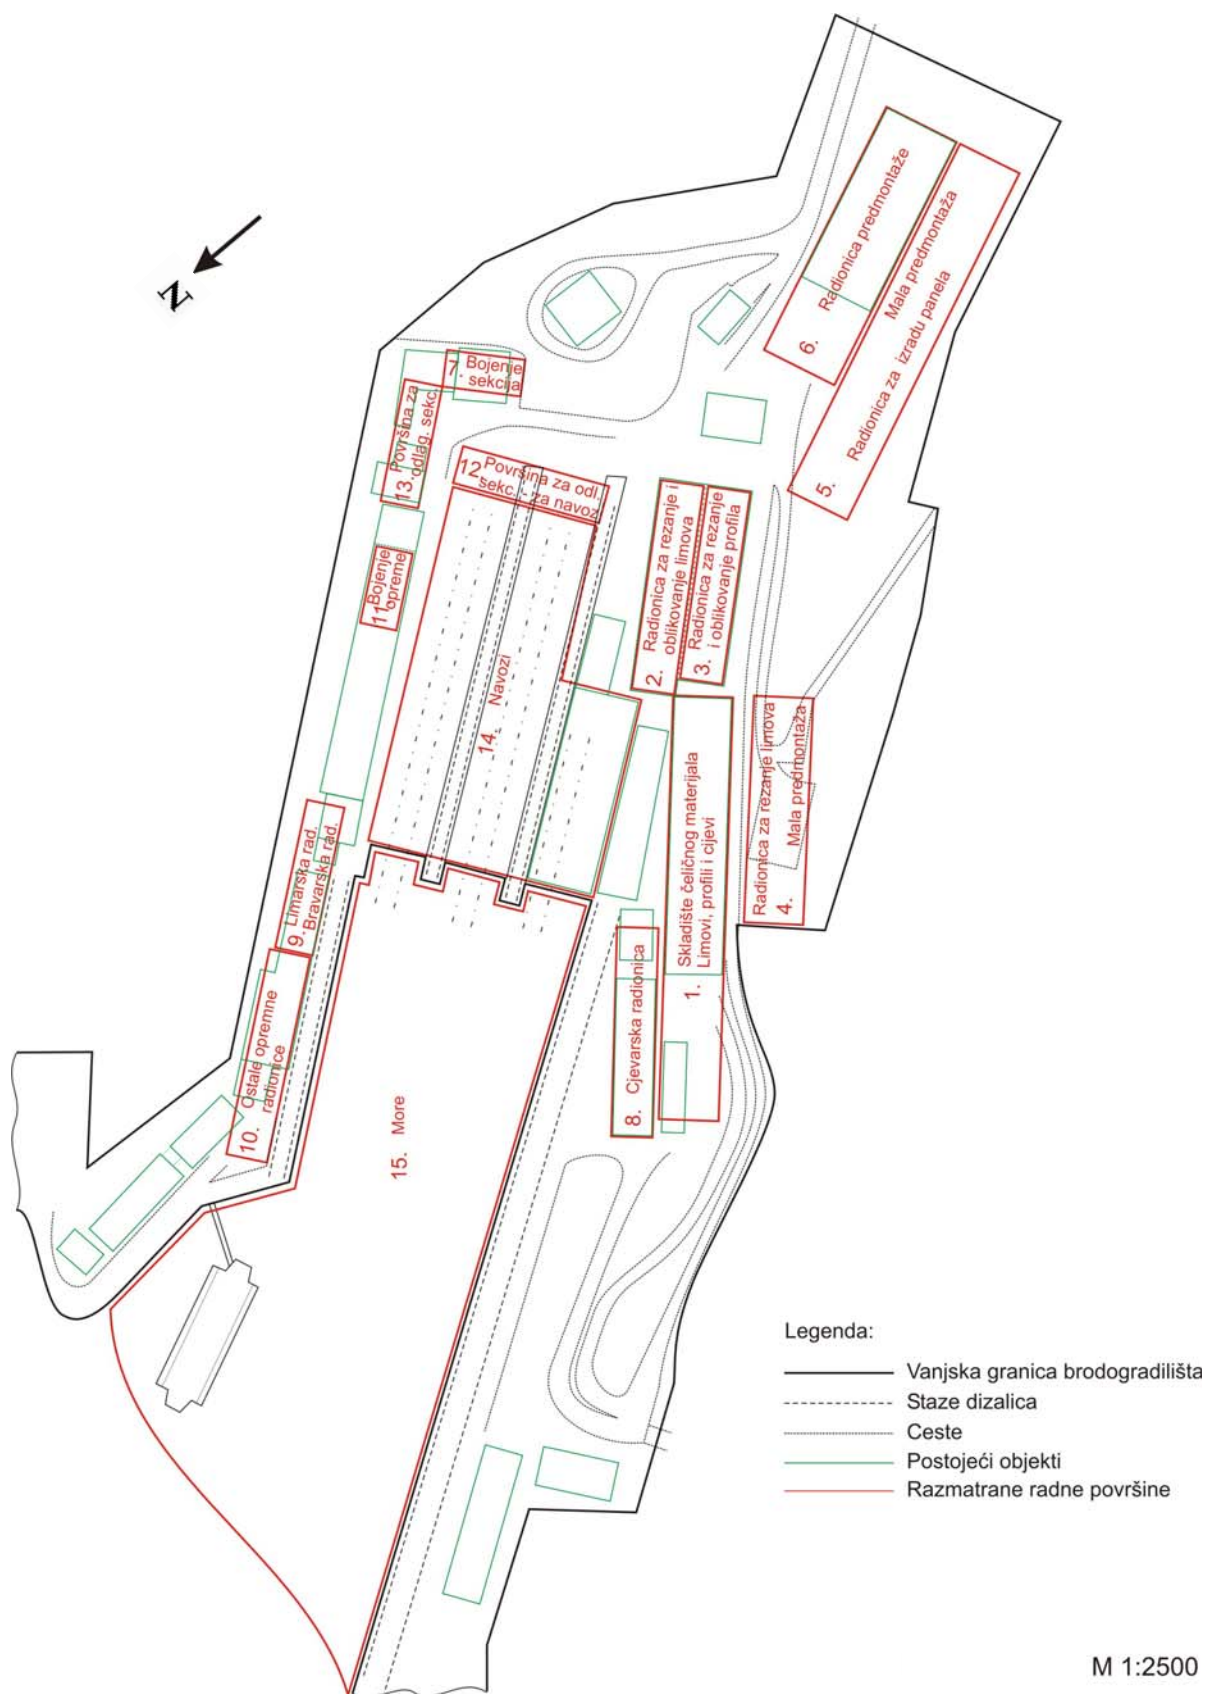
Slika 5.2.7. Prikaz varijante 7 generirane SLP metodom



Slika 5.2.8. Prikaz varijante 8 generirane SLP metodom



Slika 5.2.9. Prikaz varijante 9 generirane SLP metodom



Slika 5.2.10. Prikaz varijante 10 generirane SLP metodom

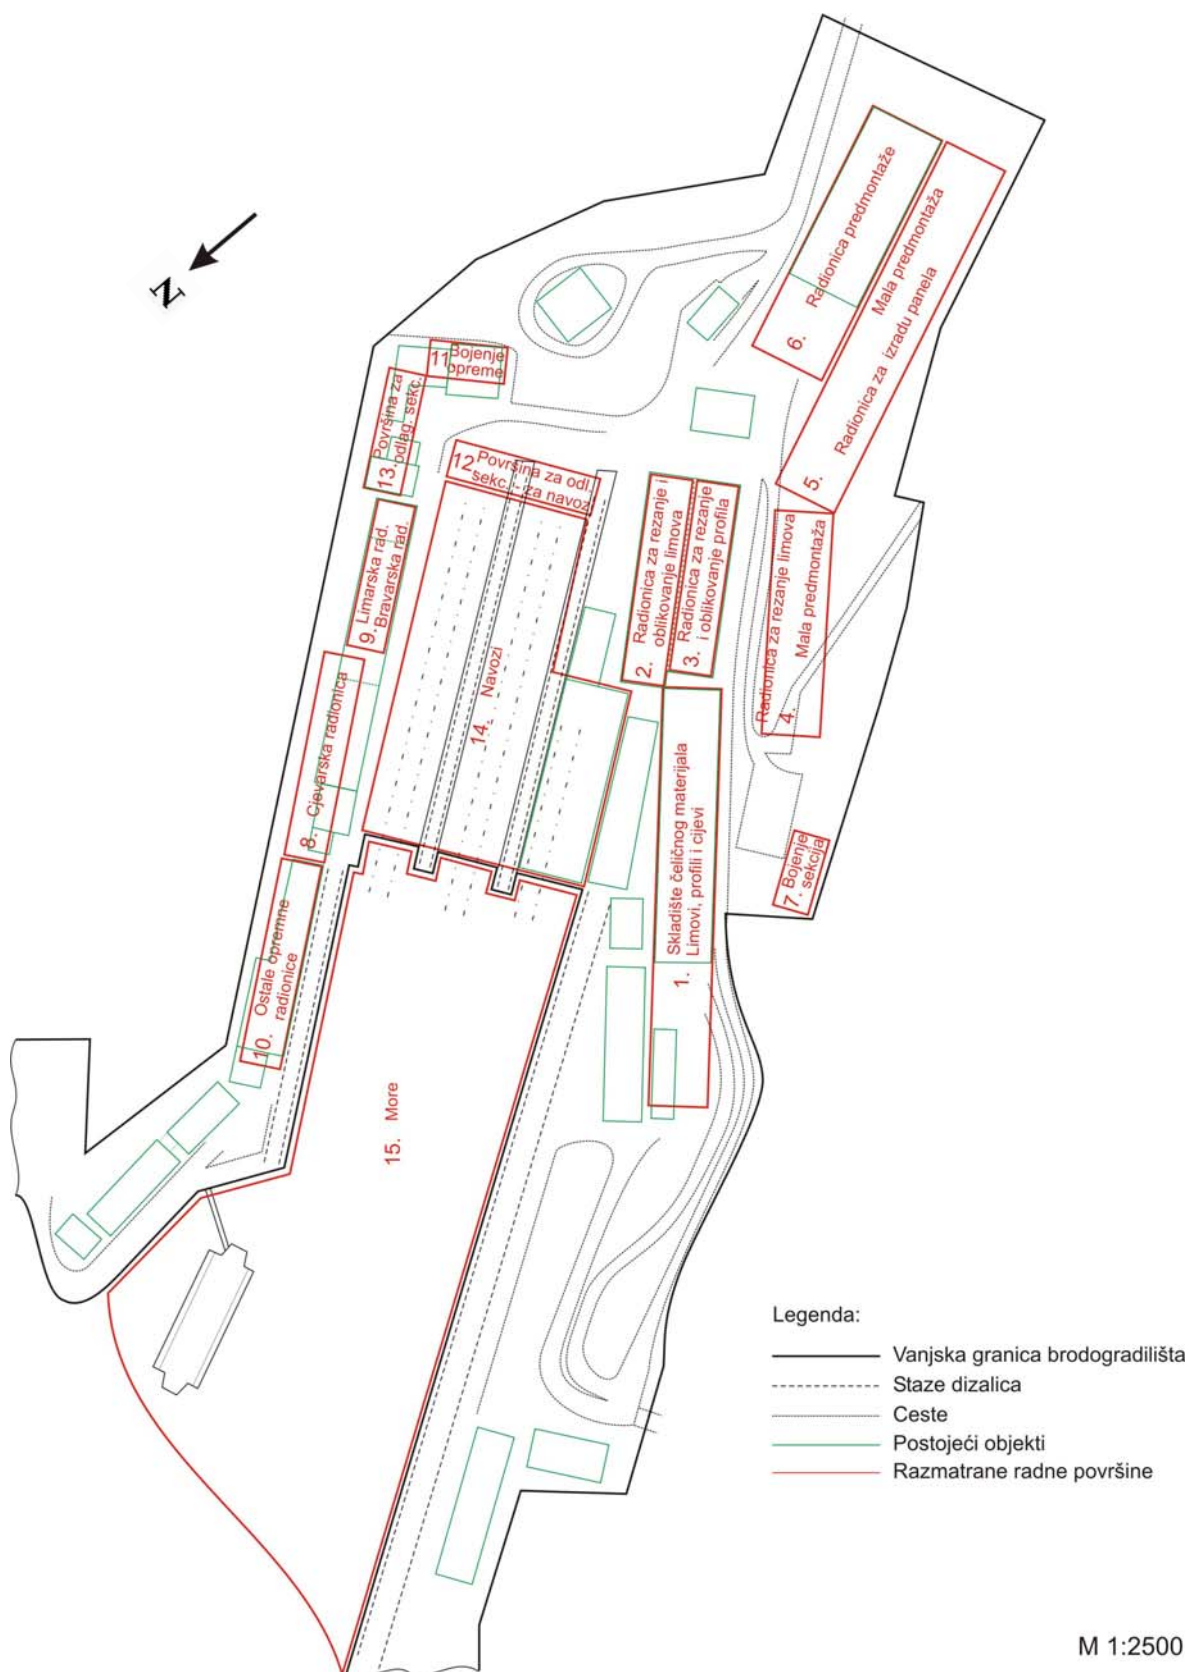
Varijanta 6, prikazana na slici 5.2.6., odabrana je s *SLP* ocjenom rasporeda površina od 0,60. Karakteristika ove varijante jest dislociran smještaj radionice za rezanje limova i radionice male predmontaže od narednih tehnoloških koraka kao što je radionica za izradu panela, te predmontaža. Detaljnom analizom varijante 6 utvrđeno je da je za njenu realizaciju potrebno rušenje 13 postojećih objekata, te ometati tekuću proizvodnju sa vrlo visokih 50%. Procjena investicije kreće se oko 24,7 milijuna eura.

Varijanta 7, prikazana na slici 5.2.7., odabrana je s *SLP* ocjenom rasporeda površina od 0,58. Nadalje, detaljnom analizom iste utvrđeno je da je za njenu realizaciju potrebno rušenje 10 postojećih objekata, te vrlo malo utjecati na tekuću proizvodnju, sa 25%. Procjena investicije kreće se oko 23,9 milijuna eura.

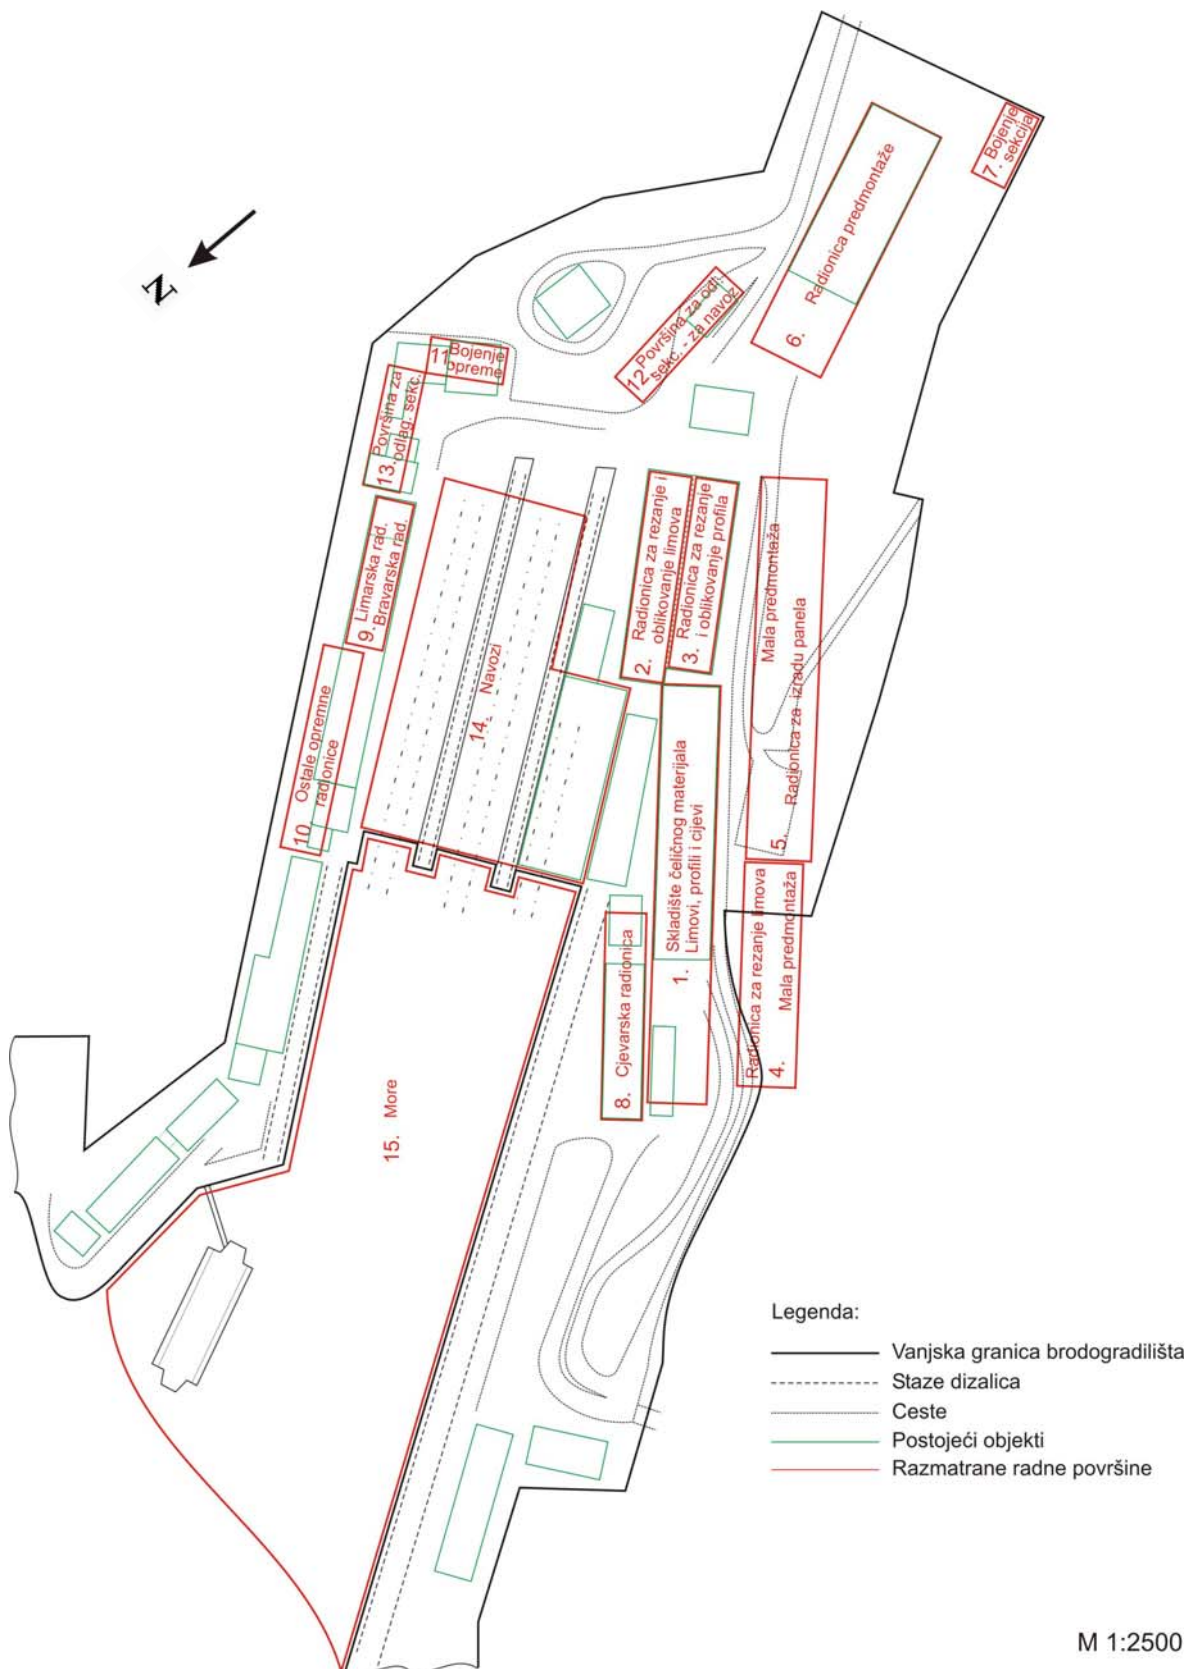
Varijanta 8, prikazana na slici 5.2.8., odabrana je s visokom *SLP* ocjenom rasporeda površina od 0,70. Međutim, slično kao i kod varijante 5, za njenu realizaciju je potrebno širenje izvan postojećih, vanjskih granica brodogradilišta. Daljnjom analizom ove varijante utvrđeno je da je za njenu realizaciju potrebno rušenje 8 postojećih objekata, te ometati tekuću proizvodnju s iznosom od 25%. Procjena investicije kreće se oko 25,7 milijuna eura.

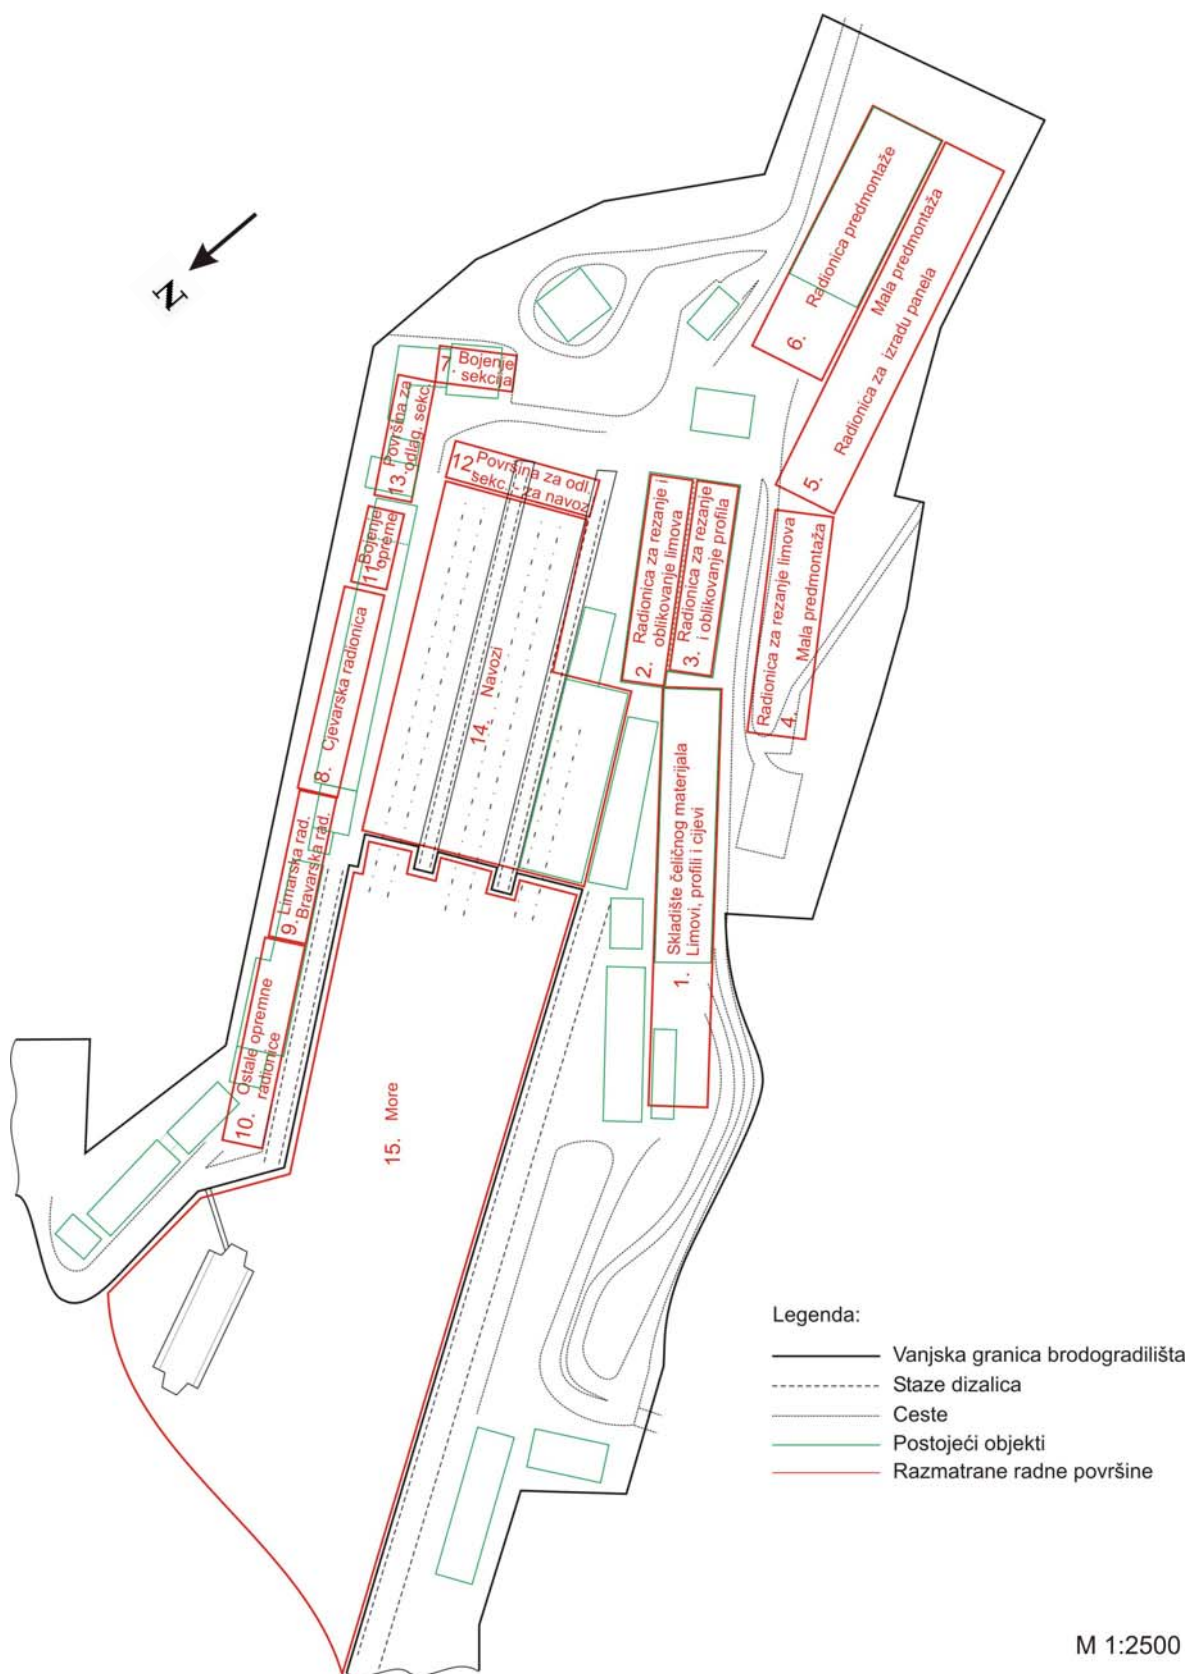
Varijanta 9, prikazana na slici 5.2.9., odabrana je s *SLP* ocjenom rasporeda površina od 0,69. Vrlo zanimljiv raspored površina te potencijalno vrlo dobro rješenje sa stajališta brodogradilišta. Loša strana ove varijante, slično kao i kod prethodne, jest potreba za manjim širenjem izvan postojećih granica brodogradilišta. Detaljnom analizom varijante 9 utvrđeno je da je za njenu realizaciju potrebno rušenje 11 postojećih objekata, te ometati tekuću proizvodnju sa 40%. Procjena investicije kreće se oko 24,9 milijuna eura.

Varijanta 10, prikazana na slici 5.2.10., odabrana je s *SLP* ocjenom rasporeda površina od 0,58. Predstavlja također jedno vrlo dobro rješenje. Analizom varijante 10 utvrđeno je da je za njenu realizaciju potrebno rušenje 11 postojećih objekata, te ometati tekuću proizvodnju također sa 40%, kao i prethodna. Procjena investicije kreće se oko 24,3 milijuna eura.

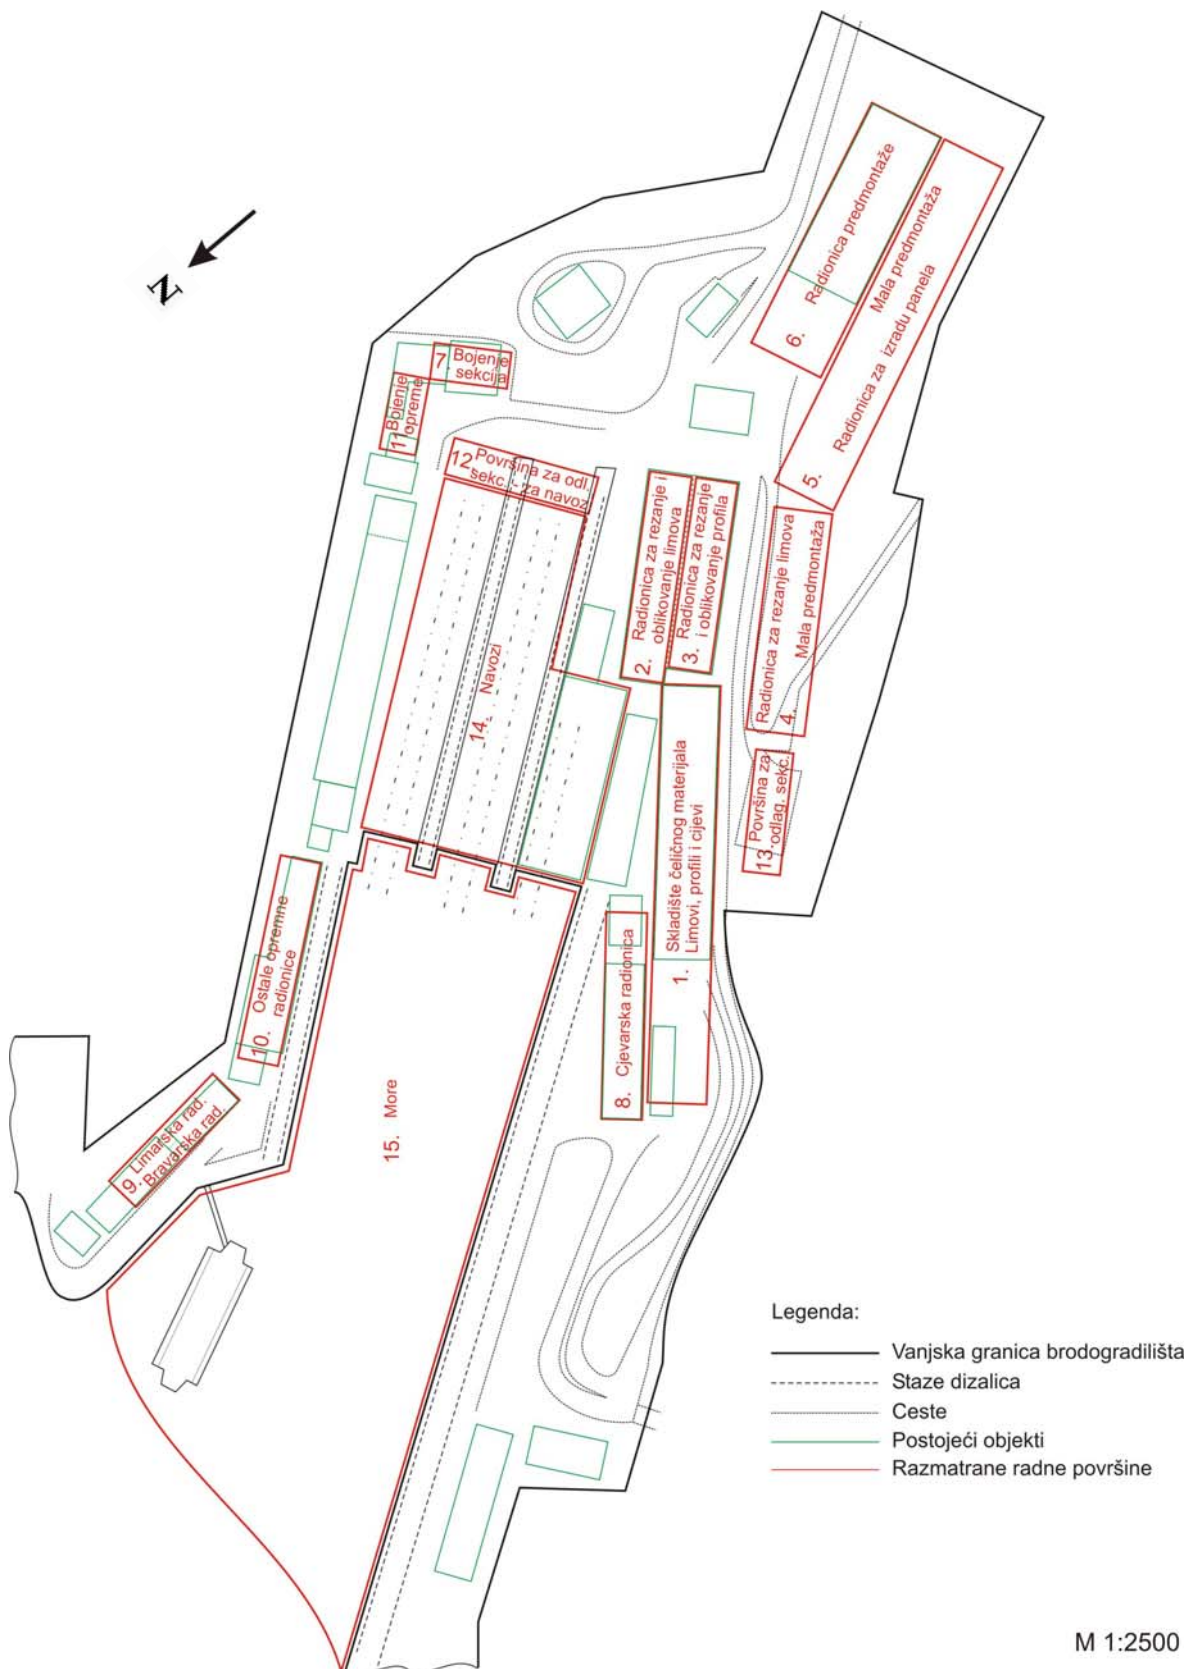


Slika 5.2.11. Prikaz varijante 11 generirane SLP metodom

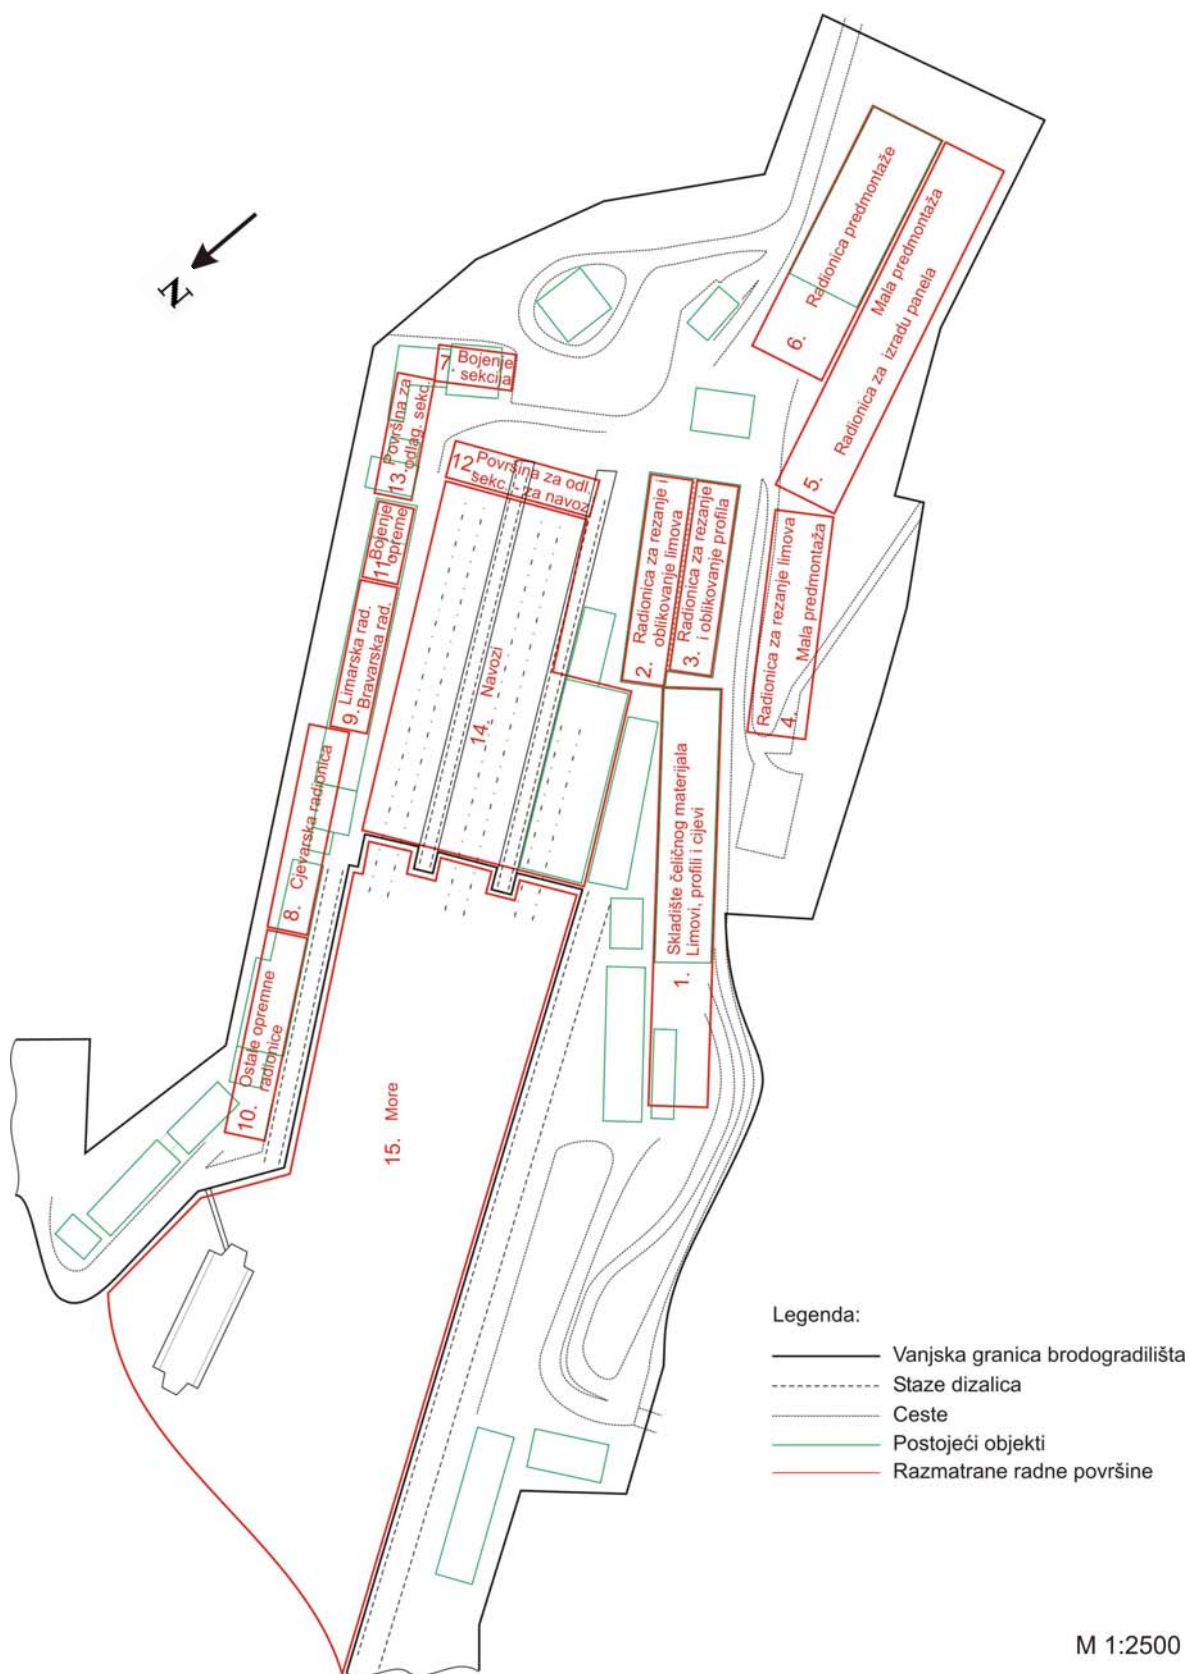
Slika 5.2.12. Prikaz varijante 12 generirane *SLP* metodom



Slika 5.2.13. Prikaz varijante 13 generirane SLP metodom



Slika 5.2.14. Prikaz varijante 14 generirane SLP metodom



M 1:2500

Slika 5.2.15. Prikaz varijante 15 generirane SLP metodom

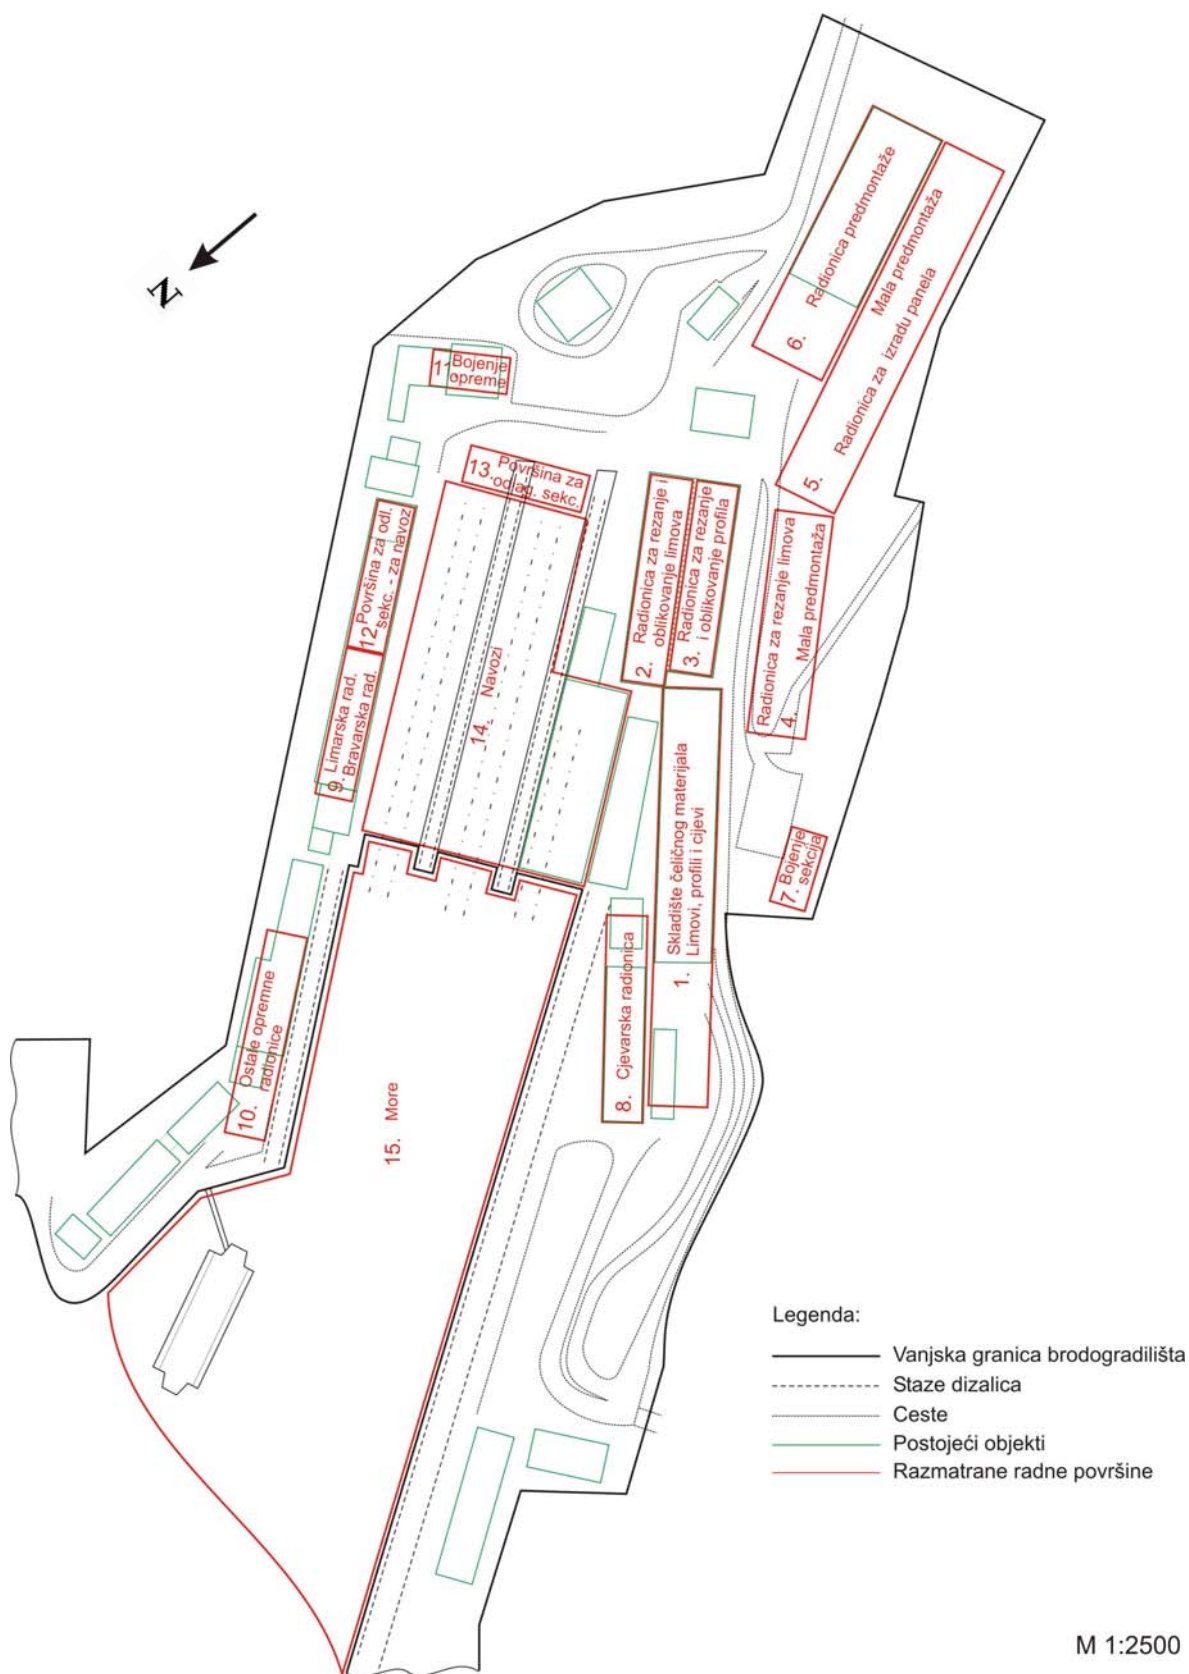
Varijanta 11, prikazana na slici 5.2.11., odabrana je s *SLP* ocjenom rasporeda površina od 0,65. Karakteristika ove varijante jest dislociran smještaj radionice za bojenje gotovih sekcija od izlaza iz radionice predmontaže ili površina za odlaganje. Detaljnom analizom varijante 11 utvrđeno je da je za njenu realizaciju potrebno rušenje 14 postojećih objekata, te ometati tekuću proizvodnju sa 30%. Procjena investicije kreće se oko 24,8 milijuna eura.

Varijanta 12, prikazana na slici 5.2.12., odabrana je s najvišom *SLP* ocjenom rasporeda površina od 0,76. Ova se varijanta najviše približava saznanjima o optimalnim proizvodnim tokovima temeljem utvrđenih odnosa bliskosti. Međutim, za realizaciju iste potrebno je širenje izvan postojećih granica brodogradilišta, što će u konkretnom slučaju predstavljati bitno ograničenje. Nadalje, detaljnom analizom iste utvrđeno je da je za njenu realizaciju potrebno rušenje 11 postojećih objekata, te ometati tekuću proizvodnju sa 30%. Procjena investicije kreće se oko 26,1 milijuna eura.


Varijanta 13, prikazana na slici 5.2.13., odabrana je s vrlo visokom *SLP* ocjenom rasporeda površina od 0,71. Slično kao kod varijante 1 proizvodne radionice smještene su s jedne strane, dok su opremne radionice smještene s druge strane navoza. Daljnjom analizom ove varijante utvrđeno je da je za njenu realizaciju potrebno rušenje 14 postojećih objekata, te ometati tekuću proizvodnju s visokim iznosom od 50%. Procjena investicije kreće se oko 24,7 milijuna eura.

Varijanta 14, prikazana na slici 5.2.14., odabrana je s *SLP* ocjenom rasporeda površina od 0,6. Karakteristika ove varijante jest dislociran smještaj površine za odlaganje gotovih sekcija. Detaljnom analizom varijante 12 utvrđeno je da je za njenu realizaciju potrebno rušenje 11 postojećih objekata, te ometati tekuću proizvodnju sa 40%. Procjena investicije kreće se oko 25,7 milijuna eura.

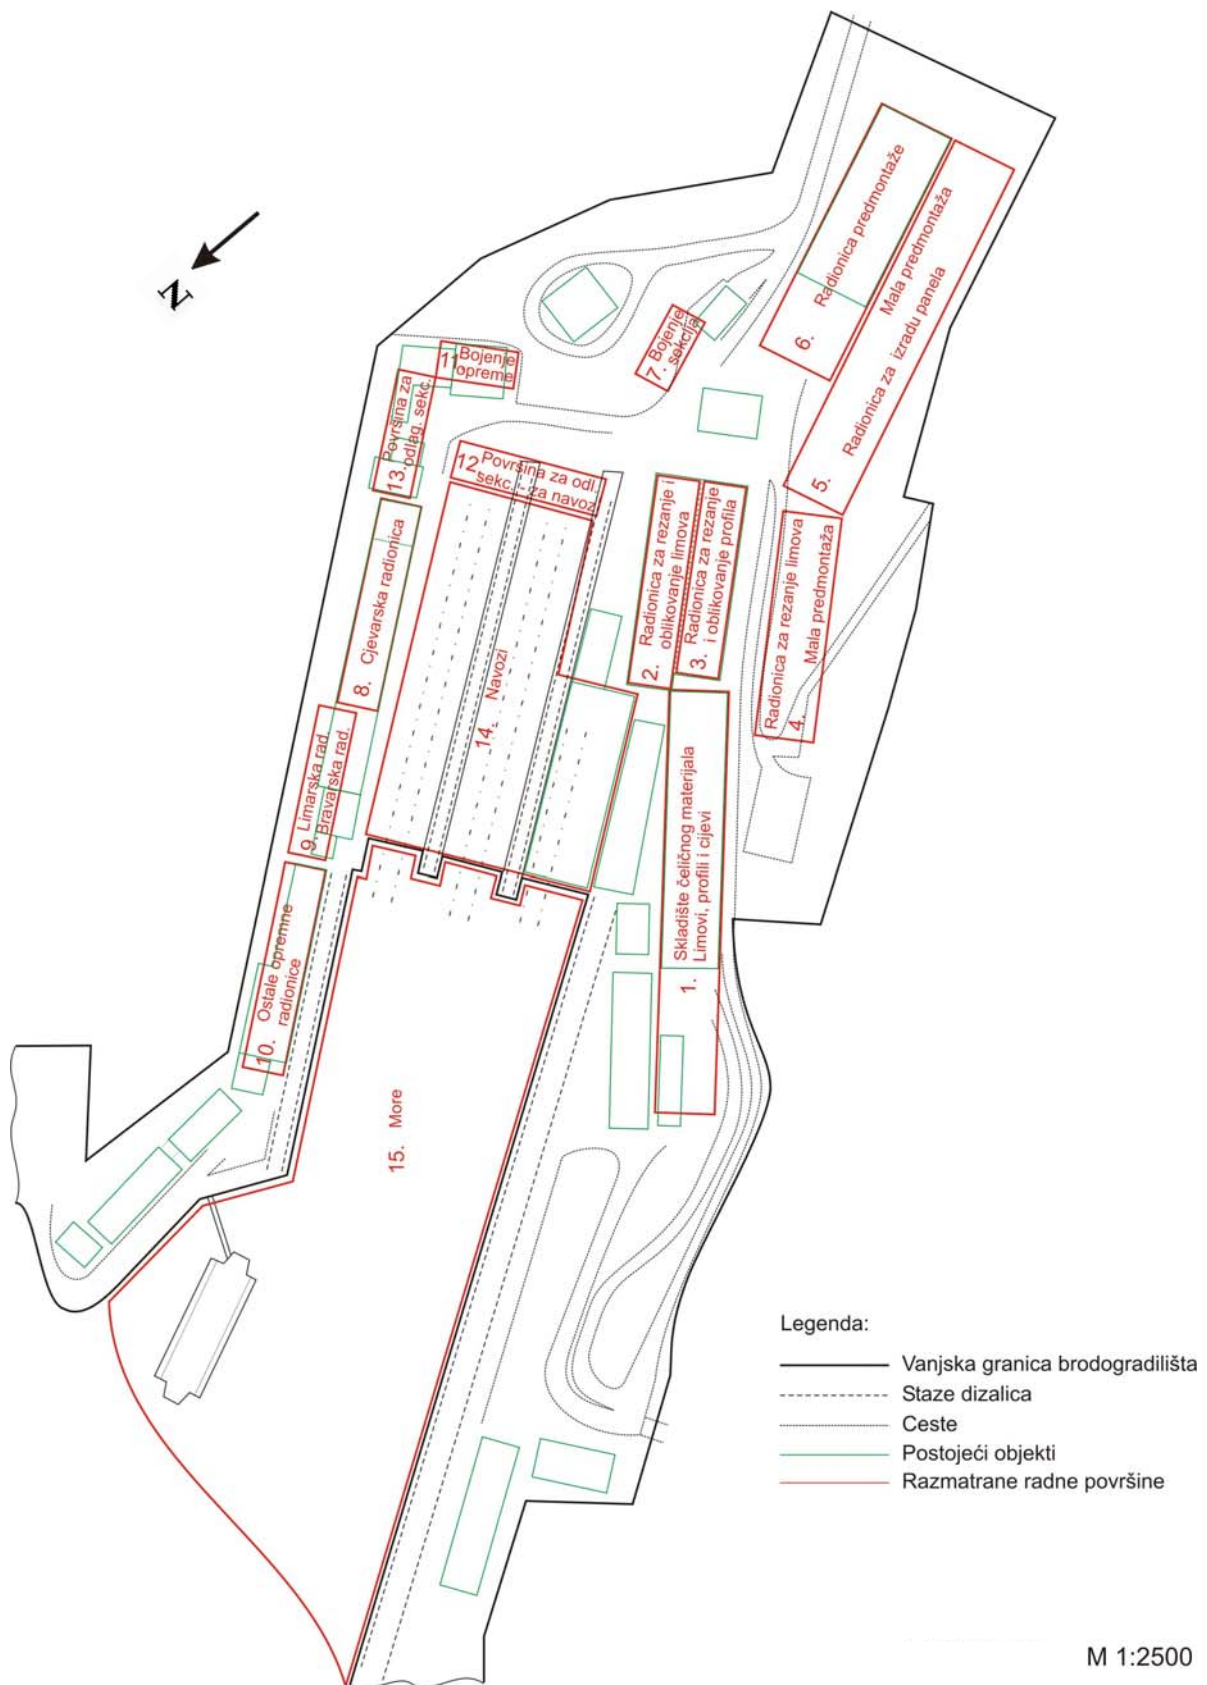
Varijanta 15, prikazana na slici 5.2.15., odabrana je s vrlo visokom *SLP* ocjenom rasporeda površina od 0,71. Predstavlja također jedno vrlo dobro rješenje. Međutim, analizom varijante 15 utvrđeno je da je za njenu realizaciju potrebno rušenje čak 14 postojećih objekata, te ometati tekuću proizvodnju također sa 40%, kao i prethodna. Procjena investicije kreće se oko 24,6 milijuna eura.



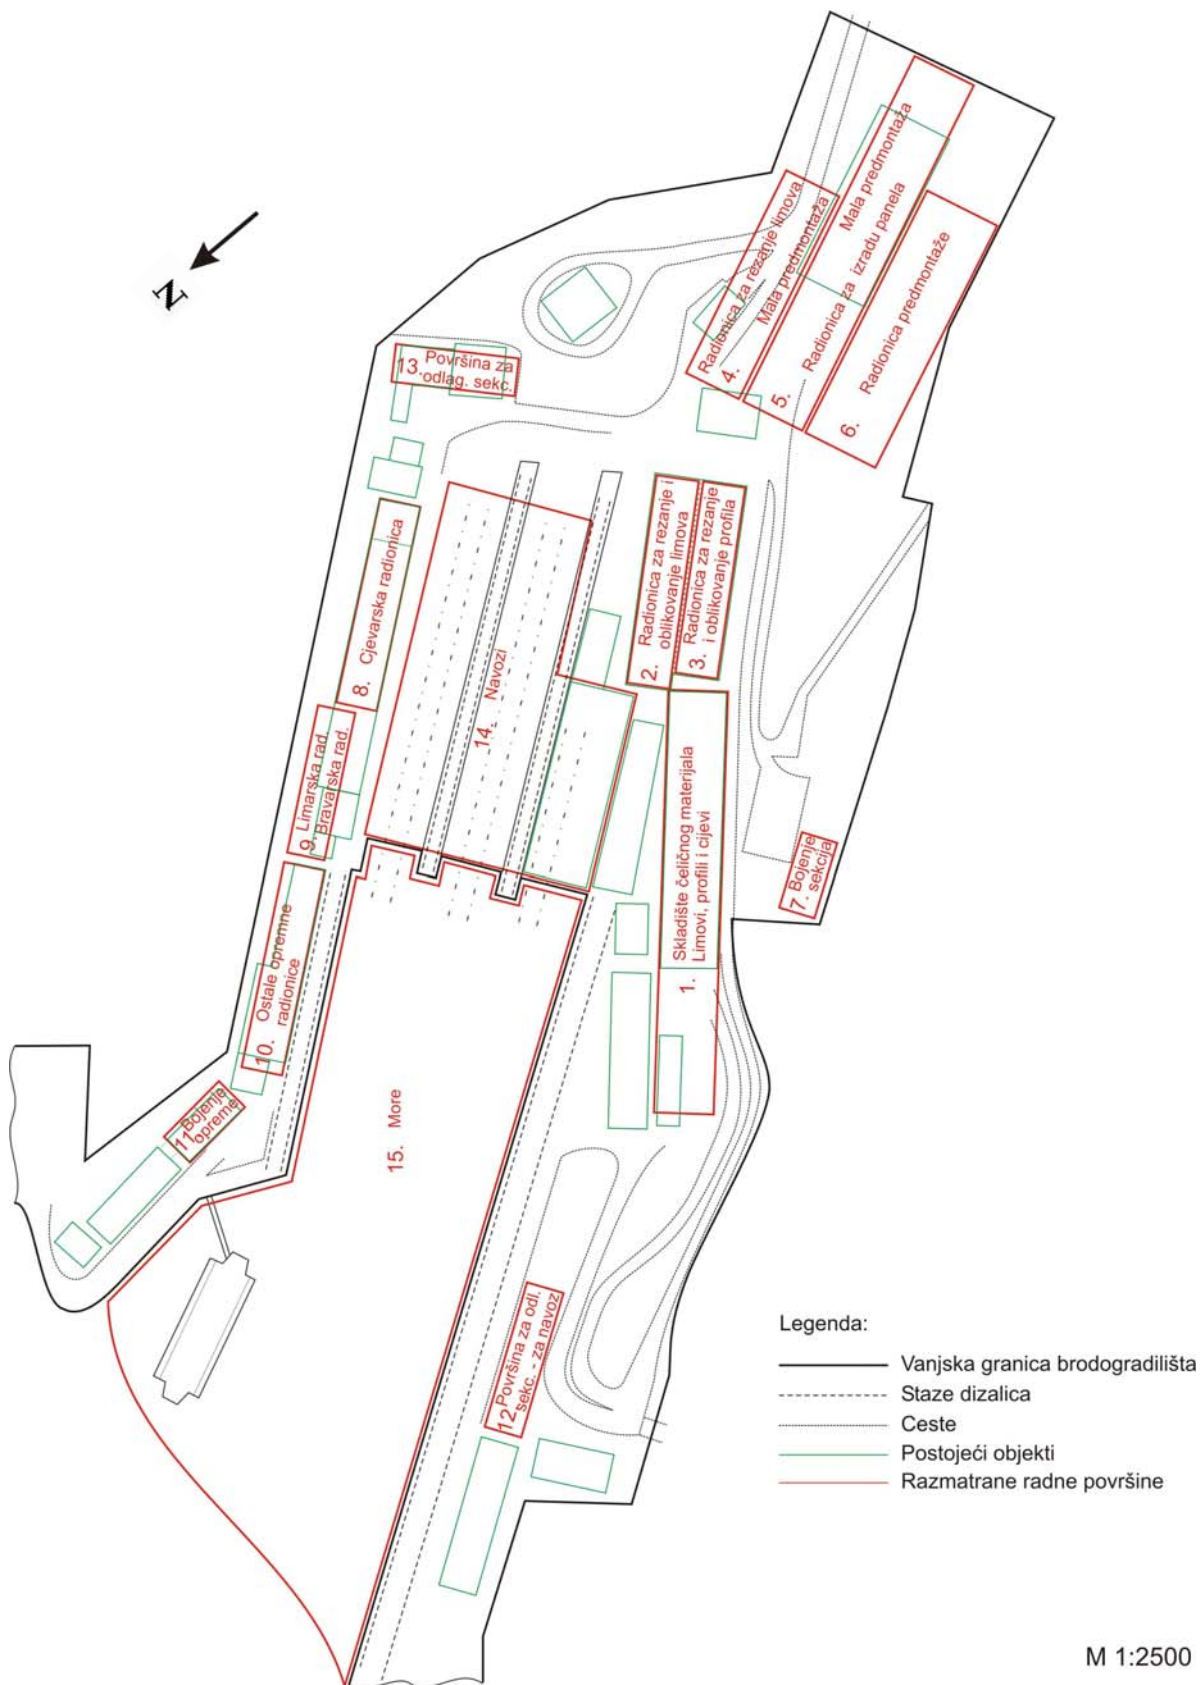
Slika 5.2.16. Prikaz varijante 16 generirane SLP metodom



Slika 5.2.17. Prikaz varijante 17 generirane SLP metodom

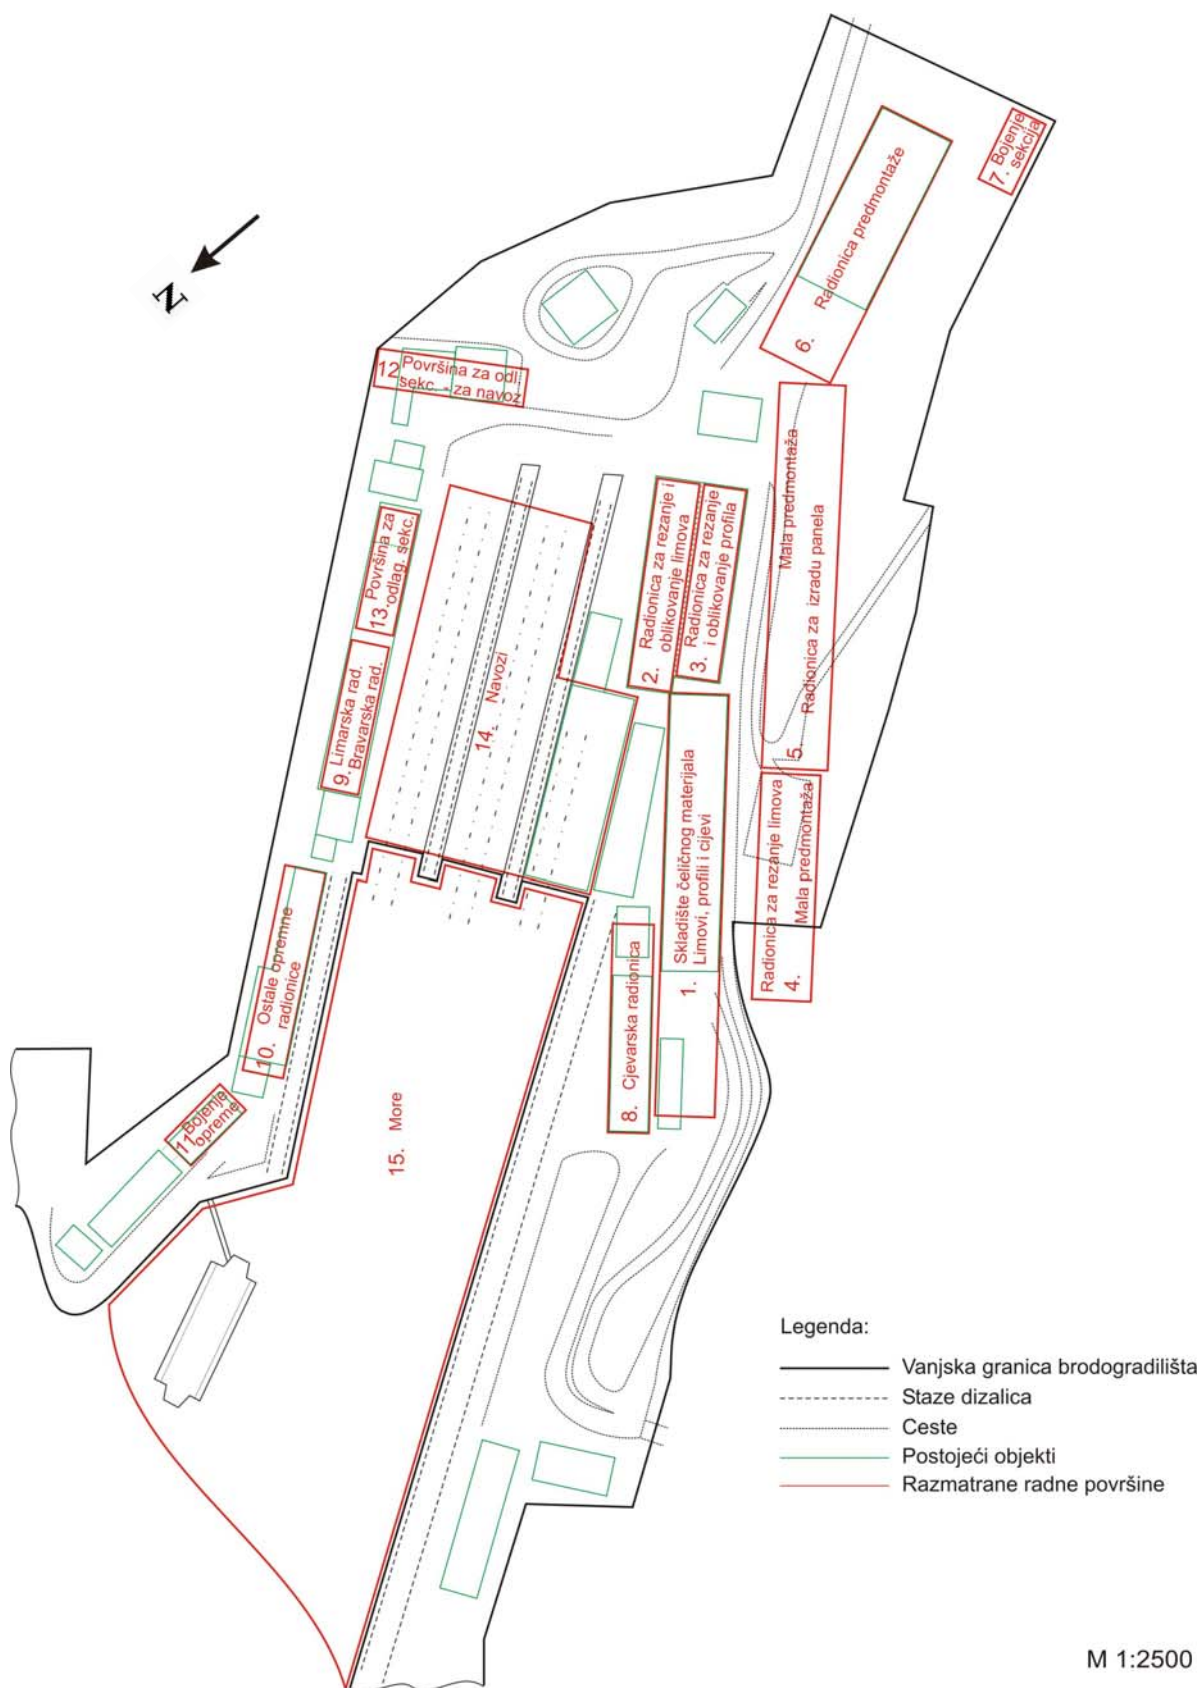


Slika 5.2.18. Prikaz varijante 18 generirane *SLP* metodom



M 1:2500

Slika 5.2.19. Prikaz varijante 19 generirane SLP metodom



M 1:2500

Slika 5.2.20. Prikaz varijante 20 generirane SLP metodom

Varijanta 16, prikazana na slici 5.2.16., odabrana je s visokom *SLP* ocjenom rasporeda površina od 0,67. Karakteristika ove varijante, kao i kod varijante 11, jest dislociran smještaj radionice za bojenje gotovih sekcija od izlaza iz radionice predmontaže ili površina za odlaganje. Detaljnom analizom varijante 16 utvrđeno je da je za njenu realizaciju potrebno rušenje 11 postojećih objekata, te ometati tekuću proizvodnju sa čak 55%. Procjena investicije kreće se oko 24,6 milijuna eura.

Varijanta 17, prikazana na slici 5.2.17., odabrana je s visokom *SLP* ocjenom rasporeda površina od 0,69. Iako se temeljem *SLP* ocjene rasporeda površina ova varijanta ne smješta u sam vrh, nju ostale karakteristike bitno favoriziraju. Analizom iste utvrđeno je da je za njenu realizaciju potrebno rušenje samo 6 postojećih objekata, te gotovo bez ometanje tekuće proizvodnje realizirati istu, sa samo 10%. Zatim ova varijanta je bitno jeftinija od ostalih, te se procjena investicije kreće oko 20,9 milijuna eura.

Varijanta 18, prikazana na slici 5.2.18., odabrana je s vrlo visokom *SLP* ocjenom rasporeda površina od 0,73. Daljnjom analizom ove varijante utvrđeno je da je za njenu realizaciju potrebno rušenje 12 postojećih objekata, te ometati tekuću proizvodnju s visokim iznosom od 30%. Procjena investicije kreće se oko 24,5 milijuna eura.

Varijanta 19, prikazana na slici 5.2.19., odabrana je s vrlo niskom *SLP* ocjenom rasporeda površina od 0,57. Predstavlja solidno projektno rješenje sa stajališta tehnološkičnosti, međutim analizom iste je utvrđeno da je za njenu realizaciju potrebno rušenje čak 13 postojećih objekata, i gotovo zaustaviti tekuću proizvodnju tijekom izvedbe. Procijenjena je i kao najskuplja varijanta, čija se investicija kreće se oko 27,8 milijuna eura. Nije vjerojatno da će konkurirati za optimalno rješenje.

Varijanta 20, prikazana na slici 5.2.20., odabrana je s vrlo visokom *SLP* ocjenom rasporeda površina od 0,73. Predstavlja također jedno vrlo dobro rješenje. Međutim, za realizaciju iste potrebno je širenje izvan postojećih granica brodogradilišta, što će u konkretnom slučaju predstavljati bitno ograničenje. Nadalje, analizom ove varijante utvrđeno je da je za njenu realizaciju potrebno rušenje čak 13 postojećih objekata, te ometati tekuću proizvodnju sa 25%. Procjena investicije kreće se oko 25,5 milijuna eura.

5.3 FAZA 3 – Projektiranje optimalnog rasporeda proizvodnih površina postojećeg brodogradilišta hijerarhijskim modeliranjem

Kako bi se mogao izvršiti odabir optimalnog rješenja između prikazanih dvadeset najizglednijih varijanti rasporeda proizvodnih površina, potrebno je utvrditi postavljena ograničenja, odnosno kriterije koje će potencijalno rješenje optimalno zadovoljiti.

Prije svega prvi postavljeni kriterij, proizašao kao rezultat druge faze predložene metodologije, odnosno:

- Kriterij 1: *SLP* ocjena rasporeda proizvodnih površina, koja predstavlja u kojoj mjeri promatrana varijanta slijedi tehnoložnost gradnje broda odnosno saznanja o optimalnim proizvodnim tokovima. Nadalje, ostali postavljeni kriteriji, proizašli su dijelom iz projektnih zahtjeva, a dijelom iz tehnoloških ograničenja brodogradilišta te su sljedeći:

- Kriterij 2: Cijena investicije,
- Kriterij 3: Zadržavanje postojećih objekata,
- Kriterij 4: Izvedivost,
- Kriterij 5: Širenje izvan vanjskih granica brodogradilišta,

Prvi kriterij, odnosno *SLP* ocjena rasporeda proizvodnih površina, je kriterij koji je izračunat na temelju odnosa bliskosti među pojedinim proizvodnim površinama, a opisuje u kojoj mjeri promatrana varijanta prati saznanja o tehnoložnosti gradnje broda te optimalnim proizvodnim tokovima brodograđevnog procesa. Kako je već spomenuto, navedeni odnosi bliskosti utvrđeni su obradom rezultata proizašlih metodom anketiranja provedenom među relevantnim znanstvenim savjetnicima i suradnicima, te stručnjacima iz razmatranog polja brodogradnje.

Nadalje, drugi kriterij, odnosno ukupna cijena investicije potrebna za realizaciju tehnološkog projekta modernizacije predstavlja ograničenje novčanih sredstva koja brodogradilište ima na raspolaganju. U tu svrhu izvršena je kalkulacija cijena svake pojedine varijante koja je uzeta u razmatranje. Uz pretpostavku da sve varijante imaju zadovoljavajuću propusnost nastoji se da ona bude što manja.

Treći kriterij, odnosno zadržavanje postojećih objekata jest zahtjev uprave brodogradilišta prema kojemu se nastoji zadržati postojeće objekte u što je moguće većoj

mjeri budući se u većini njih odvija tekuća proizvodnja. Svako rušenje postojećeg objekta zahtjevalo bi prilagodbe u svrhu očuvanja tekuće proizvodnje. Stoga se postojeće objekte nastoji prenamijeniti i/ili modernizirati.

Izvedivost, jest četvrti kriterij koji opisuje u kojoj mjeri će investicija prilikom realizacije utjecati na poremećaje u tekućoj proizvodnji. Zahtjeva se mogućnost realizacije tehnološke modernizacije brodogradilišta, tj. optimizacije rasporeda proizvodnih površina i pripadajućih proizvodnih tokova brodograđevnog procesa na način da proizvodnja u tijeku trpi minimalne zastoje.

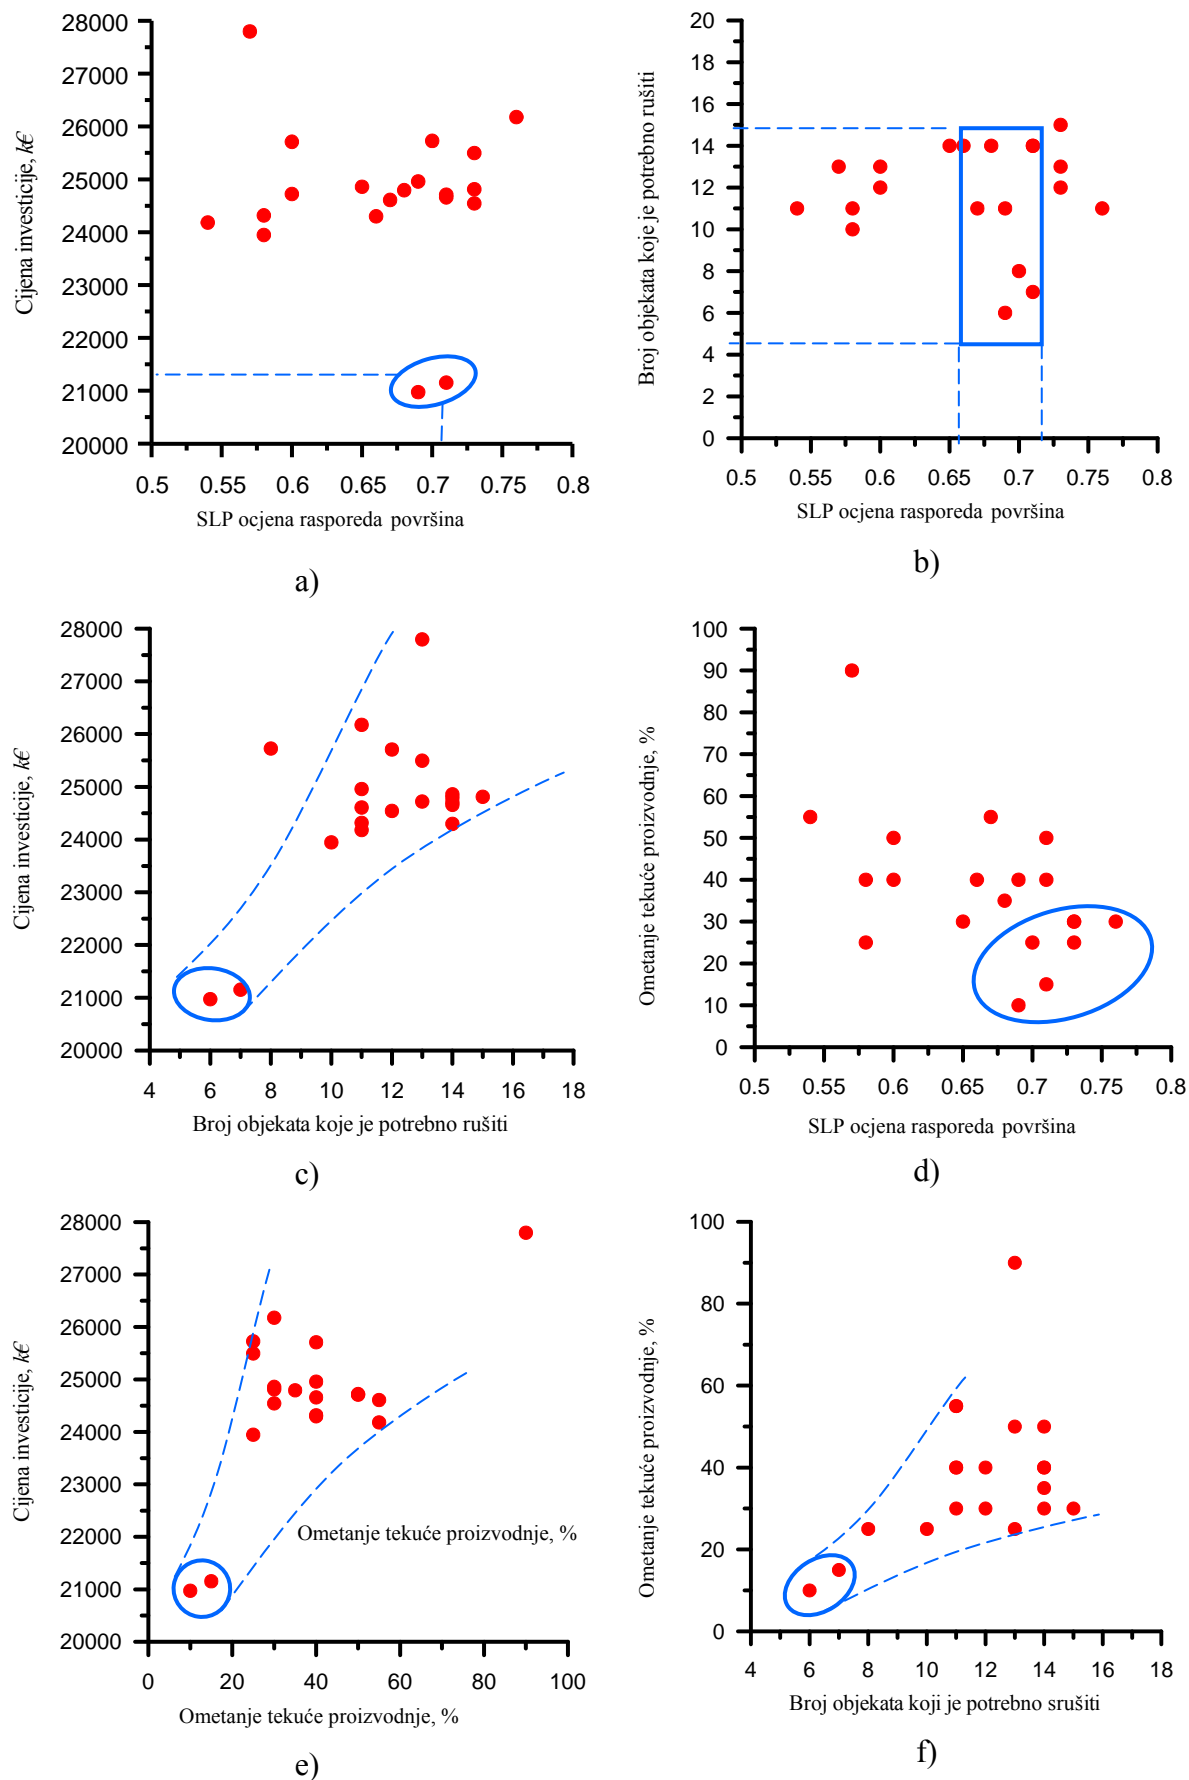
Nadalje, peti kriterij proizašao je iz analize imovinsko pravnih odnosa u okruženju brodogradilišta. Zaključak je da širenje izvan postojećih granica brodogradilišta nije poželjno jer zahtjeva otkup novih zemljišnih čestica. Otkup određenih čestica kod konkretnog problema mogao bi predstavljati značajnu vremensku prepreku dok otkup određenih čestica nije moguć.

S obzirom na postavljene kriterije izvršena je detaljna analiza osnovnih karakteristika odabranih alternativa, te su iste prikazane u tablici 5.3.1. U prvom stupcu navedene tablice ispisane su redom sve alternative, numerirane od 1 do 20. U prvom retku navedeni su utvrđeni kriteriji numerirani od 1 do 5. Svakom numeriranom retku, alternativni, pripadaju određene vrijednosti u numeriranim stupcima koje vrijede za taj redak. Primjerice, ako promatramo numerirani redak pod rednim brojem 1, tada promatramo varijantu 1. Za nju se u stupcu br. 1 nalazi vrijednost 0,66 dobivena na temelju kriterija 1, odnosno predstavlja vrijednost *SLP* ocijene rasporeda površina. U stupcu br. 2 vrijednost 24299 predstavlja cijenu potrebnu za realizaciju varijante 1. Taj broj zapravo znači cijenu od 24.299.000,00 € (slovima:dvadeset i četiri milijuna dvije stotine devedeset devet tisuća eura). U stupcu br.3 promatranog retka br.1 nalazi se broj 14, odnosno prema trećem kriteriju predstavlja broj objekata koje je potrebno rušiti da bi se promatrana varijanta realizirala. Zatim, vrijednost stupca br. 4, odnosno broj 40 predstavlja u kojoj će mjeri, izraženo u postocima, realizacija promatrane varijante narušiti tekuću proizvodnju. U zadnjem stupcu dan je odgovor NE, vezan uz kriterij 5, odnosno da li postoji potreba za širenjem izvan postojećih granica brodogradilišta.

Tablica 5.3.1. Osnovne karakteristike alternativa prema postavljenim kriterijima

<div style="display: flex; justify-content: space-between; align-items: center;"> <div style="transform: rotate(-45deg); white-space: nowrap;">KRITERIJI</div> <div style="transform: rotate(45deg); white-space: nowrap;">ALTERNATIVE</div> </div>		1	2	3	4	5
		<i>SLP ocjena rasporeda površina</i>	<i>Cijena investicije, k]</i>	<i>Broj objekata koje je potrebno srušiti</i>	<i>Ometanje tekuće proizvodnje, %</i>	<i>Potreba za širenjem izvan granica brodogradilišta</i>
1	<i>Varijanta 1</i>	0,66	24299	14	40	NE
2	<i>Varijanta 2</i>	0,71	21154	7	15	NE
3	<i>Varijanta 3</i>	0,54	24182	11	55	NE
4	<i>Varijanta 4</i>	0,68	24794	14	35	NE
5	<i>Varijanta 5</i>	0,73	24812	15	30	DA
6	<i>Varijanta 6</i>	0,6	24722	13	50	NE
7	<i>Varijanta 7</i>	0,58	23947	10	25	NE
8	<i>Varijanta 8</i>	0,7	25727	8	25	DA
9	<i>Varijanta 9</i>	0,69	24959	11	40	DA
10	<i>Varijanta 10</i>	0,58	24317	11	40	NE
11	<i>Varijanta 11</i>	0,65	24859	14	30	NE
12	<i>Varijanta 12</i>	0,76	26177	11	30	DA
13	<i>Varijanta 13</i>	0,71	24709	14	50	NE
14	<i>Varijanta 14</i>	0,6	25709	12	40	NE
15	<i>Varijanta 15</i>	0,71	24659	14	40	NE
16	<i>Varijanta 16</i>	0,67	24609	11	55	NE
17	<i>Varijanta 17</i>	0,69	20974	6	10	NE
18	<i>Varijanta 18</i>	0,73	24544	12	30	NE
19	<i>Varijanta 19</i>	0,57	27797	13	90	NE
20	<i>Varijanta 20</i>	0,73	25497	13	25	DA

Međusobne zavisnosti pojedinih vrijednosti osnovnih karakteristika odabranih alternativa prikazane su na slici 5.3.1



Slika 5.3.1. Međusobni odnosi vrijednosti osnovnih karakteristika alternativa

Iz prikazanih zavisnosti mogu se donijeti određeni zaključci. Jedan je taj da cijena investicije nije pravilno povezana s *SLP* ocjenom rasporeda površina, slika 5.3.1 a). Međutim isto tako, na spomenutoj slici, vide se varijante koje imaju dobru *SLP* ocjenu rasporeda površina, a istovremeno su bitno jeftinije od drugih (zaokružene plavom bojom).

Zatim, broj objekata koji se ruši također nije pravilno povezan s *SLP* ocjenom rasporeda površina, slika 5.3.1 b). Stoga postoje varijante s sličnim vrijednostima *SLP* ocjene, a većom razlikom u broju objekata koje je potrebno srušiti, kako je vidljivo unutar kvadrata plave boje. U tom slučaju treba odabrati one varijante kod kojih se ruši manje objekata.

Nadalje, vidljivo je da cijena investicije slijedi određenu pravilnost u odnosu na broj objekata koji se ruše, 5.3.1 c). Navedeno proizlazi iz činjenice da rušenje zahtjeva sredstva, te ponovna gradnja novih objekata također zahtjeva određena sredstva. Zatim, za vrijeme rušenja i gradnje tekuća proizvodnja unutar takvih objekata je zaustavljena. Stoga, kako je i zaokruženo plavom bojom, postoje varijante koje ne zahtijevaju velik broj rušenja postojećih objekata, te su istovremeno vrlo prihvatljive sa stajališta cijene investicije.

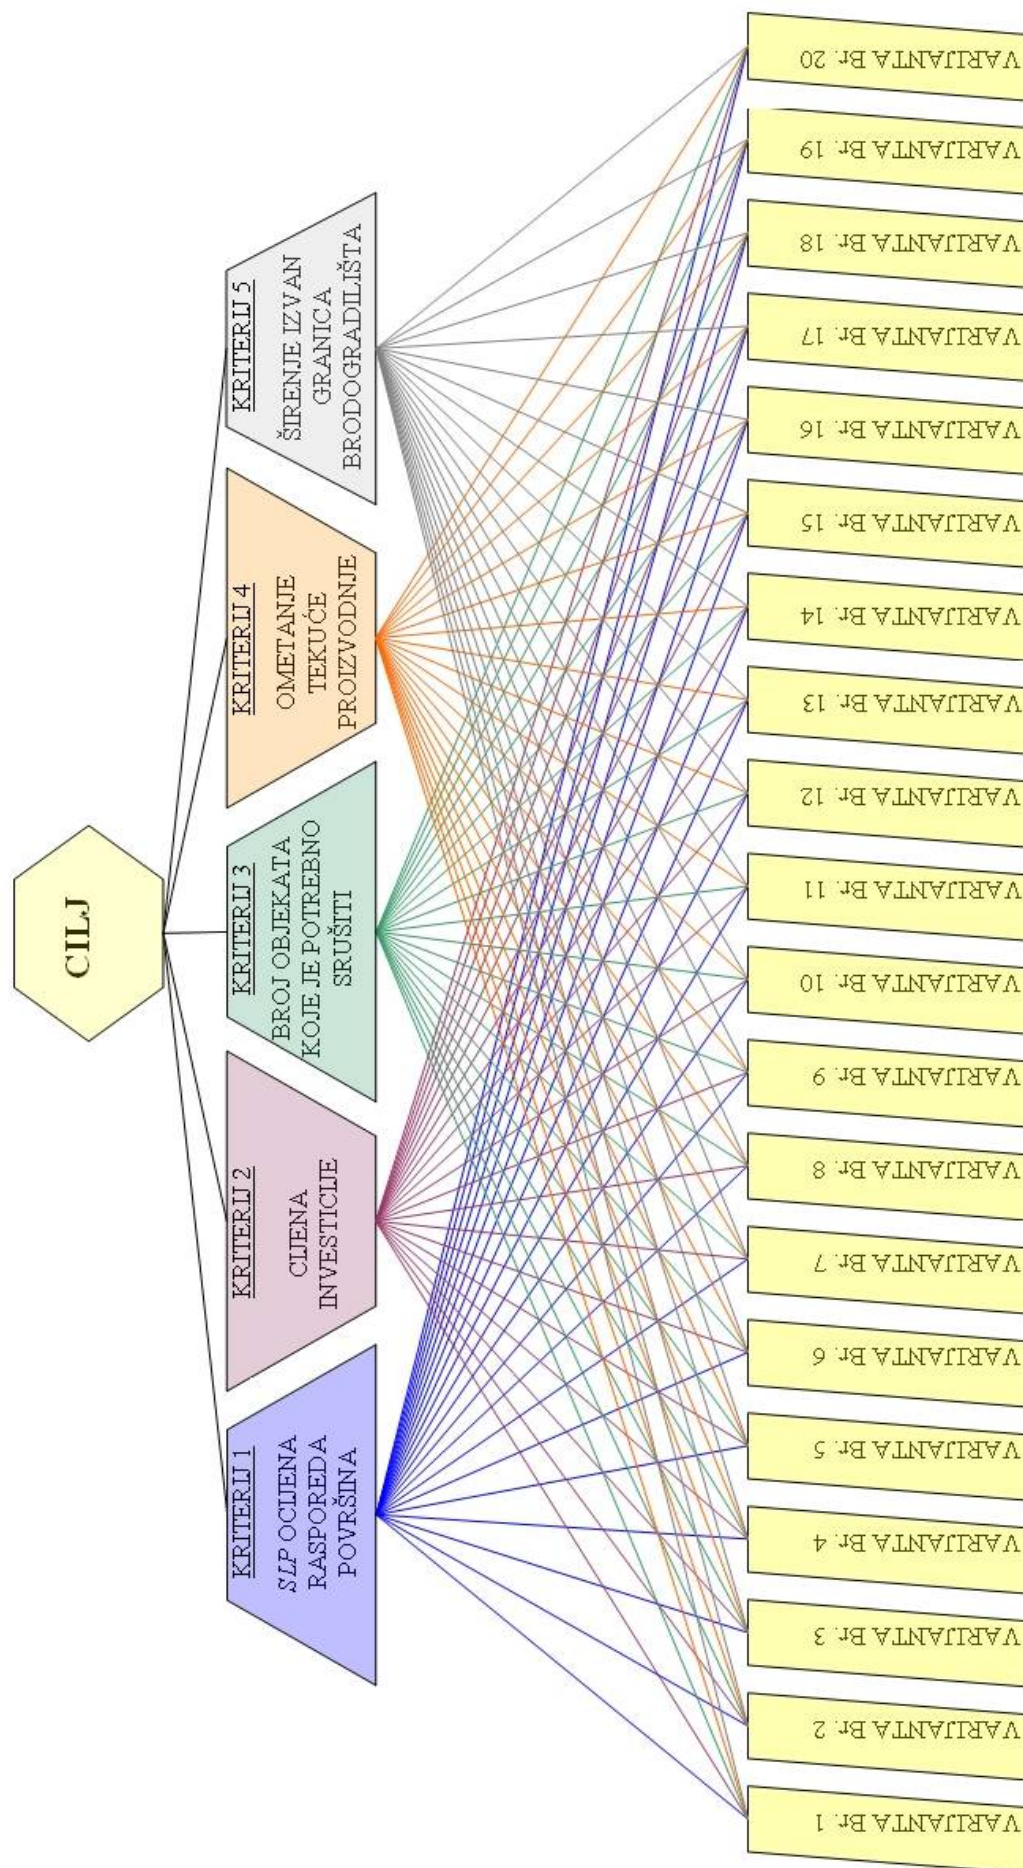
Također se može zaključiti da ometanje postojeće proizvodnje nije usko povezano s *SLP* rasporedom površina, slika 5.3.1 d). U tom slučaju potrebno je težiti onim varijantama koje će imati što veću *SLP* ocjenu rasporeda površina a pritom što manje ometaju postojeću proizvodnju. Takve varijante nalaze se unutar područja omeđenog plavom bojom.

Vidi se da postoji određena pravilnost odnosa ometanja postojeće proizvodnje s cijenom investicije, 5.3.1 e). Što je ometanje postojeće proizvodnje manje, manji su i troškovi brodogradilišta. Dakle, zaokružene su varijante koje su povoljne po cijeni, a istovremeno ne utječu bitno na zastoj tekuće proizvodnje.

Slično tomu, broj objekata koji se ruši direktno utječe na ometanje postojeće proizvodnje, 5.3.1 f). Stoga je potrebno težiti onim varijantama koje neće zahtijevati rušenje velikog broja postojećih objekata za svoju realizaciju, jer tada neće biti bitnog utjecaja na poremećaje i zastoje u tekućoj proizvodnji. Takve varijante zaokružene su plavim.

Nadalje, u okviru ove faze izrađen je hijerarhijski model projektiranja koji se temelji na problemu višekriterijskog odlučivanja u kojemu je cilj, opisan u poglavlju 3, lociran na najvišoj hijerarhijskoj razini. Na sljedećoj nižoj razini locirano je pet kriterija opisanih u poglavlju 5.3. Na najnižoj hijerarhijskoj razini locirane su alternative kao dvadeset varijanti rješenja. Navedene alternative prikazane su i opisane u poglavlju 5.2.

Na slici 5.3.2. prikazan je takav razvijeni model za razmatrani realni problem postojećeg brodogradilišta. Na slici su vidljive međusobne veze pojedinih hijerarhijskih razina.



Slika 5.3.2. AHP model, hijerarhijska struktura realnog problema

U okviru realnog problema, u svakom čvoru hijerarhijske strukture, pomoću Saaty-jeve skale, u parovima su se međusobno uspoređivali elementi tog čvora koji su se nalazili neposredno ispod njega i izračunavale njihove lokalne težine korištenjem *AHP* metode. Pritom su se kriteriji međusobno uspoređivali u parovima u odnosu na koliko puta je jedan od njih važniji od drugog u funkciji cilja. Zatim su se alternative međusobno uspoređivale u parovima po svakom od kriterija procjenjujući u kojoj mjeri se po tom kriteriju jednoj od njih daje prednost u odnosu na drugu.

Iz procjena relativnih važnosti elemenata odgovarajuće razine hijerarhijske strukture problema izračunate su lokalne težine kriterija, a na posljednjoj razini lokalni prioriteti alternativa. Nadalje, ukupni prioriteti alternativa izračunati su tako da su se njihovi lokalni prioriteti ponderirali s težinama svih čvorova kojima pripadaju gledajući od najniže razine u hijerarhijskom modelu prema najvišoj i zatim zbrojili.

Procjene omjera težina kriterija za realni problem dane su u Tablici 5.3.2. Navedene procjene generirale su se ekspertnim pristupom uz pomoć tima ljudi iz postojećeg brodogradilišta uključenih u projekt modernizacije.

Tablica 5.3.2. Omjeri težina kriterija

Red. br.	Omjeri težina kriterija	<u>Kriterij 1</u> SLP ocjena rasporeda površina	<u>Kriterij 2</u> Cijena investicije	<u>Kriterij 3</u> Broj objekata koje je potrebno srušiti	<u>Kriterij 4</u> Ometanje tekuće proizvodnje	<u>Kriterij 5</u> Širenje izvan granica brodograd.
1	<u>Kriterij 1</u> SLP ocjena rasporeda površina	1	1/5	1/3	1/3	1/3
2	<u>Kriterij 2</u> Cijena investicije	5	1	3	1	3
3	<u>Kriterij 3</u> Broj objekata koje je potrebno srušiti	3	1/3	1	1	1/3
4	<u>Kriterij 4</u> Ometanje tekuće proizvodnje	3	1	1	1	1
5	<u>Kriterij 5</u> Širenje izvan granica brodograd.	3	1/3	3	1	1

Primjerice, iz retka br. 2, tablice 5.3.2. kriterij 2, odnosno cijena investicije, prema Saaty-jevoj skali, ima jaku dominantnost, 5:1, u odnosu na kriterij 1, tj. u odnosu na *SLP* ocjenu rasporeda površina. Zatim isti kriterij 2, prema Saaty-jevoj skali, dominira s omjerom 3:1 u odnosu na kriterij 3, tj. u odnosu na zadržavanje postojećih objekata. Iz slike je vidljivo također da su kriterij 2, odnosno cijena investicije, i kriterij 4, odnosno izvedivost investicije, jednakog značaja (1:1). Nadalje, kriterij 2 dominira s omjerom 3:1 u odnosu na kriterij 5, tj. u odnosu na potrebe širenja izvan postojećih granica brodogradilišta.

U postupku analitičkog hijerarhijskog procesa došlo se i do pojedinih vrijednosti težina kriterija kako je prikazano u tablici 5.3.3. Kao najvažniji proizašao je kriterij 2, odnosno cijena investicije, zatim redom kriterij 5, kriterij 4, kriterij 3, te kriterij 1.

Tablica 5.3.3. Vrijednosti težina kriterija

	<u>Kriterij 1</u> <i>SLP</i> ocjena rasporeda površina	<u>Kriterij 2</u> Cijena investicije	<u>Kriterij 3</u> Broj objekata koje je potrebno srušiti	<u>Kriterij 4</u> Ometanje tekuće proizvodnje	<u>Kriterij 5</u> Širenje izvan granica brodograd.
Vrijednost težine kriterija, w_n	0,061	0,370	0,138	0,212	0,218

Nadalje izvršena je provjera konzistentnosti dobivenih vrijednosti težina kriterija, pa prema (11) vrijedi:

$$\begin{bmatrix} a_{11} & a_{12} & a_{13} & a_{14} & a_{15} \\ a_{21} & a_{22} & a_{23} & a_{24} & a_{25} \\ a_{31} & a_{32} & a_{33} & a_{34} & a_{35} \\ a_{41} & a_{42} & a_{43} & a_{44} & a_{45} \\ a_{51} & a_{52} & a_{53} & a_{54} & a_{55} \end{bmatrix} \cdot \begin{bmatrix} w_1 \\ w_2 \\ w_3 \\ w_4 \\ w_5 \end{bmatrix} = \begin{bmatrix} 1 & \frac{1}{5} & \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \\ 5 & 1 & 3 & 1 & 3 \\ 3 & \frac{1}{3} & 1 & 1 & \frac{1}{3} \\ 3 & 1 & 1 & 1 & 1 \\ 3 & \frac{1}{3} & 3 & 1 & 1 \end{bmatrix} \cdot \begin{bmatrix} 0,061 \\ 0,370 \\ 0,138 \\ 0,212 \\ 0,218 \end{bmatrix} = \begin{bmatrix} 0,324 \\ 1,955 \\ 0,729 \\ 1,121 \\ 1,150 \end{bmatrix} \quad (17)$$

b_n
 \downarrow

Zatim prema (12) slijedi:

$$\begin{bmatrix} b_1/w_1 \\ b_2/w_2 \\ b_3/w_3 \\ b_4/w_4 \\ b_5/w_5 \end{bmatrix} = \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \lambda_3 \\ \lambda_4 \\ \lambda_5 \end{bmatrix} \Rightarrow \begin{bmatrix} 0,324 \\ 0,061 \\ 1,955 \\ 0,370 \\ 0,729 \\ 0,138 \\ 1,121 \\ 0,212 \\ 1,150 \\ 0,218 \end{bmatrix} = \begin{bmatrix} 5,311 \\ 5,284 \\ 5,283 \\ 5,288 \\ 5,275 \end{bmatrix} \quad (18)$$

te prema vrijedi (13):

$$\lambda_{\max} = \frac{1}{n} \sum_{i=1}^n \lambda_i = \frac{5,311 + 5,284 + 5,283 + 5,288 + 5,275}{5} = 5,288 \quad (19)$$

Prema (10) se vrši izračun indeksa konzistentnosti, CI , te prema (14) konačno stupanj konzistentnosti, za vrijednost slučajnog indeksa, $RI_5=1,12$:

$$CI = \frac{\lambda_{\max} - n}{n - 1} = \frac{5,288 - 5}{5 - 1} = 0,072 \Rightarrow CR = \frac{CI}{RI} = 0,06 < 0,10 \quad (20)$$

Rezultat je manji od 0,10 i smatra se dovoljno točnim te nema potrebe za korekcijama u omjerima težina kriterija tj. izabranim pripadajućim vrijednostima iz tablice 5.3.2.

Nadalje, radi prikaza tijeka proračuna, u daljnjem tekstu formirane su matrice prema izrazu (4) unutar kojih su uneseni podaci o uspoređivanju u parovima temeljem Saaty-jeve skale za pojedine kriterije, gdje se prvi red i prvi stupac odnose na varijantu 1, drugi red i drugi stupac odnose se na varijantu 2, itd. Međutim radi lakšeg i bržeg rada, a za potrebe razmatranog realnog problema razvijen je prilagođeni alat unutar *Microsoft Excel-a* koji temeljem analitičkog hijerarhijskog procesa vrši izračun lokalnih te finalno

ukupnih prioriteta alternativa rasporeda proizvodnih površina brodogradilišta. Sam proračun i rezultati dobiveni razvijenim prilagođenim alatom prikazani su u prilogu 3.

Matrica A_1 , izraz (21), odnosi se na uspoređivanje u parovima temeljem prvog kriterija, odnosno temeljem SLP ocijene rasporeda površina. Dok se matrica A_2 , izraz (22), odnosi na uspoređivanje u parovima temeljem drugog kriterija, odnosno temeljem cijene ukupne investicije. Nadalje, matrica A_3 , izraz (23), odnosi se na uspoređivanje u parovima temeljem trećeg kriterija, odnosno u ovisnosti o broju zadržanih postojećih objekata. Matrica A_4 , izraz (24), odnosi se na uspoređivanje u parovima temeljem četvrtog kriterija, odnosno u odnosu na izvedivost investicije sa stajališta zaustavljanja tekuće proizvodnje. Te zaključno, matrica A_5 , izraz (25), odnosi se na uspoređivanje u parovima temeljem petog kriterija, odnosno u pogledu širenja izvan postojećih granica brodogradilišta.

$$A_1 = \begin{bmatrix} 1 & \frac{1}{5} & 5 & 1 & \frac{1}{5} & 3 & 5 & \frac{1}{3} & 1 & 3 & 1 & \frac{1}{7} & \frac{1}{3} & 3 & \frac{1}{3} & 1 & 1 & \frac{1}{5} & 3 & \frac{1}{5} \\ 5 & 1 & 7 & 3 & 1 & 5 & 5 & 3 & 3 & 5 & 3 & \frac{1}{3} & 1 & 5 & 1 & 3 & 3 & 1 & 5 & 1 \\ \frac{1}{5} & 1 & 1 & \frac{1}{7} & \frac{1}{9} & \frac{1}{3} & \frac{1}{3} & \frac{1}{7} & \frac{1}{5} & \frac{1}{3} & \frac{1}{5} & \frac{1}{9} & \frac{1}{9} & \frac{1}{3} & \frac{1}{9} & \frac{1}{7} & \frac{1}{7} & \frac{1}{9} & \frac{1}{3} & \frac{1}{9} \\ 1 & \frac{1}{3} & 7 & 1 & \frac{1}{3} & 5 & 5 & 1 & 1 & 5 & 3 & \frac{1}{5} & 1 & 5 & 1 & 1 & 1 & \frac{1}{3} & 7 & \frac{1}{3} \\ 5 & 1 & 9 & 3 & 1 & 7 & 7 & 3 & 3 & 7 & 5 & 1 & 1 & 7 & 1 & 3 & 3 & 1 & 7 & 1 \\ \frac{1}{3} & \frac{1}{5} & 3 & \frac{1}{5} & \frac{1}{7} & 1 & 1 & \frac{1}{5} & \frac{1}{5} & 1 & \frac{1}{3} & \frac{1}{7} & \frac{1}{7} & 1 & \frac{1}{7} & \frac{1}{5} & \frac{1}{5} & \frac{1}{7} & 1 & \frac{1}{7} \\ \frac{1}{5} & \frac{1}{5} & 3 & \frac{1}{5} & \frac{1}{7} & 1 & 1 & \frac{1}{5} & \frac{1}{5} & 1 & \frac{1}{3} & \frac{1}{7} & \frac{1}{7} & 1 & \frac{1}{7} & \frac{1}{5} & \frac{1}{5} & \frac{1}{7} & 1 & \frac{1}{7} \\ 3 & \frac{1}{3} & 7 & 1 & \frac{1}{3} & 5 & 5 & 1 & 3 & 5 & 3 & \frac{1}{3} & 1 & 5 & 1 & 3 & 3 & 1 & 5 & 1 \\ 1 & \frac{1}{3} & 5 & 1 & \frac{1}{3} & 5 & 5 & \frac{1}{3} & 1 & 5 & 3 & \frac{1}{3} & 1 & 5 & 1 & 3 & 3 & 1 & 5 & 1 \\ \frac{1}{3} & \frac{1}{5} & 3 & \frac{1}{5} & \frac{1}{7} & 1 & 1 & \frac{1}{5} & \frac{1}{5} & 1 & \frac{1}{3} & \frac{1}{7} & \frac{1}{7} & 1 & \frac{1}{7} & \frac{1}{5} & \frac{1}{5} & \frac{1}{7} & 1 & \frac{1}{7} \\ 1 & \frac{1}{3} & 5 & \frac{1}{3} & \frac{1}{5} & 3 & 3 & \frac{1}{3} & \frac{1}{3} & 3 & 1 & \frac{1}{7} & \frac{1}{3} & 3 & \frac{1}{3} & 1 & 1 & \frac{1}{5} & 3 & \frac{1}{5} \\ 7 & 3 & 9 & 5 & 1 & 7 & 7 & 3 & 3 & 7 & 7 & 1 & 1 & 7 & 1 & 3 & 3 & 1 & 7 & 1 \\ 3 & 1 & 9 & 1 & 1 & 7 & 7 & 1 & 1 & 7 & 3 & 1 & 1 & 5 & 1 & 3 & 3 & 1 & 5 & 1 \\ \frac{1}{3} & \frac{1}{5} & 3 & \frac{1}{5} & \frac{1}{7} & 1 & 1 & \frac{1}{5} & \frac{1}{5} & 1 & \frac{1}{3} & \frac{1}{7} & \frac{1}{5} & 1 & \frac{1}{7} & \frac{1}{5} & \frac{1}{5} & \frac{1}{7} & 1 & \frac{1}{7} \\ 3 & 1 & 9 & 1 & 1 & 7 & 7 & 1 & 1 & 7 & 3 & 1 & 1 & 7 & 1 & 3 & 3 & 1 & 5 & 1 \\ 1 & \frac{1}{3} & 7 & 1 & \frac{1}{3} & 5 & 5 & \frac{1}{3} & \frac{1}{3} & 5 & 1 & \frac{1}{3} & \frac{1}{3} & 5 & \frac{1}{3} & 1 & 1 & \frac{1}{3} & 7 & \frac{1}{3} \\ 1 & \frac{1}{3} & 7 & 1 & \frac{1}{3} & 5 & 5 & \frac{1}{3} & \frac{1}{3} & 5 & 1 & \frac{1}{3} & \frac{1}{3} & 5 & \frac{1}{3} & 1 & 1 & 1 & 5 & 1 \\ 5 & 1 & 9 & 3 & 1 & 7 & 7 & 1 & 1 & 7 & 5 & 1 & 1 & 7 & 1 & 3 & 1 & 1 & 7 & 1 \\ \frac{1}{3} & \frac{1}{5} & 3 & \frac{1}{7} & \frac{1}{7} & 1 & 1 & \frac{1}{5} & \frac{1}{5} & 1 & \frac{1}{3} & \frac{1}{7} & \frac{1}{5} & 1 & \frac{1}{5} & \frac{1}{7} & \frac{1}{5} & \frac{1}{7} & 1 & \frac{1}{7} \\ 5 & 1 & 9 & 3 & 1 & 7 & 7 & 1 & 1 & 7 & 5 & 1 & 1 & 7 & 1 & 3 & 1 & 1 & 7 & 1 \end{bmatrix} \quad (21)$$

$$A_2 = \begin{bmatrix} 1 & \frac{1}{3} & 1 & 2 & 2 & 2 & 1 & 3 & 3 & 1 & 2 & 7 & 2 & 3 & 2 & 2 & 1 & \frac{1}{5} & 7 & 3 \\ 3 & 1 & 3 & 5 & 5 & 5 & 3 & 7 & 7 & 3 & 5 & 8 & 5 & 7 & 4 & 4 & \frac{1}{2} & 4 & 8 & 7 \\ 1 & \frac{1}{3} & 1 & 3 & 3 & 3 & 1 & 5 & 3 & 1 & 3 & 7 & 3 & 4 & 3 & 3 & \frac{1}{5} & 3 & 7 & 5 \\ \frac{1}{2} & \frac{1}{5} & \frac{1}{3} & 1 & 1 & 1 & \frac{1}{3} & 3 & 1 & \frac{1}{3} & 1 & 5 & 1 & 3 & 1 & 1 & \frac{1}{7} & 1 & 5 & 3 \\ \frac{1}{2} & \frac{1}{5} & \frac{1}{3} & 1 & 1 & 1 & \frac{1}{3} & 3 & 1 & \frac{1}{3} & 1 & 5 & 1 & 3 & 1 & 1 & \frac{1}{7} & 1 & 5 & 3 \\ \frac{1}{2} & \frac{1}{5} & \frac{1}{3} & 1 & 1 & 1 & \frac{1}{3} & 3 & 1 & \frac{1}{3} & 1 & 5 & 1 & 3 & 1 & 1 & \frac{1}{7} & 1 & 5 & 3 \\ 1 & \frac{1}{3} & 1 & 3 & 3 & 3 & 1 & 3 & 3 & 1 & 2 & 7 & 2 & 3 & 2 & 2 & \frac{1}{5} & 1 & 7 & 3 \\ \frac{1}{3} & \frac{1}{7} & \frac{1}{5} & \frac{1}{3} & \frac{1}{3} & \frac{1}{3} & \frac{1}{3} & 1 & \frac{1}{3} & \frac{1}{5} & \frac{1}{3} & 3 & \frac{1}{3} & 1 & \frac{1}{3} & \frac{1}{3} & \frac{1}{8} & \frac{1}{4} & 3 & 1 \\ \frac{1}{3} & \frac{1}{7} & \frac{1}{3} & 1 & 1 & 1 & \frac{1}{3} & 3 & 1 & \frac{1}{3} & 1 & 5 & 1 & 3 & 1 & 1 & \frac{1}{7} & 1 & 5 & 3 \\ 1 & \frac{1}{3} & 1 & 3 & 3 & 3 & 1 & 5 & 3 & 1 & 2 & 7 & 2 & 3 & 2 & 2 & \frac{1}{5} & 1 & 7 & 3 \\ \frac{1}{2} & \frac{1}{5} & \frac{1}{3} & 1 & 1 & 1 & \frac{1}{2} & 3 & 1 & \frac{1}{2} & 1 & 5 & 1 & 3 & 1 & 1 & \frac{1}{7} & 1 & 5 & 3 \\ \frac{1}{7} & \frac{1}{8} & \frac{1}{7} & \frac{1}{5} & \frac{1}{5} & \frac{1}{5} & \frac{1}{7} & \frac{1}{3} & \frac{1}{5} & \frac{1}{7} & \frac{1}{5} & 1 & \frac{1}{5} & \frac{1}{3} & \frac{1}{5} & \frac{1}{5} & \frac{1}{9} & \frac{1}{5} & 2 & \frac{1}{3} \\ \frac{1}{2} & \frac{1}{5} & \frac{1}{3} & 1 & 1 & 1 & \frac{1}{2} & 3 & 1 & \frac{1}{2} & 1 & 5 & 1 & 3 & 1 & 1 & \frac{1}{7} & 1 & 5 & 3 \\ \frac{1}{3} & \frac{1}{7} & \frac{1}{4} & \frac{1}{3} & \frac{1}{3} & \frac{1}{3} & \frac{1}{3} & 1 & \frac{1}{3} & \frac{1}{3} & \frac{1}{3} & 3 & \frac{1}{3} & 1 & \frac{1}{3} & \frac{1}{3} & \frac{1}{8} & \frac{1}{4} & 3 & 1 \\ \frac{1}{2} & \frac{1}{4} & \frac{1}{3} & 1 & 1 & 1 & \frac{1}{2} & 3 & 1 & \frac{1}{2} & 1 & 5 & 1 & 3 & 1 & 1 & \frac{1}{7} & 1 & 5 & 3 \\ \frac{1}{2} & \frac{1}{4} & \frac{1}{3} & 1 & 1 & 1 & \frac{1}{2} & 3 & 1 & \frac{1}{2} & 1 & 5 & 1 & 3 & 1 & 1 & \frac{1}{7} & 1 & 5 & 3 \\ 5 & 2 & 5 & 7 & 7 & 7 & 5 & 8 & 7 & 5 & 7 & 9 & 7 & 8 & 7 & 7 & 1 & 7 & 9 & 7 \\ 1 & \frac{1}{4} & \frac{1}{3} & 1 & 1 & 1 & 1 & 4 & 1 & 1 & 1 & 5 & 1 & 4 & 1 & 1 & \frac{1}{7} & 1 & 5 & 3 \\ \frac{1}{7} & \frac{1}{8} & \frac{1}{7} & \frac{1}{5} & \frac{1}{5} & \frac{1}{5} & \frac{1}{7} & \frac{1}{3} & \frac{1}{5} & \frac{1}{7} & \frac{1}{5} & \frac{1}{2} & \frac{1}{5} & \frac{1}{3} & \frac{1}{5} & \frac{1}{5} & \frac{1}{9} & \frac{1}{5} & 1 & \frac{1}{3} \\ \frac{1}{3} & \frac{1}{7} & \frac{1}{5} & \frac{1}{3} & \frac{1}{3} & \frac{1}{3} & \frac{1}{3} & 1 & \frac{1}{3} & \frac{1}{3} & \frac{1}{3} & 3 & \frac{1}{3} & 1 & \frac{1}{3} & \frac{1}{3} & \frac{1}{7} & \frac{1}{3} & 3 & 1 \end{bmatrix} \quad (22)$$

[illegible]

[illegible]

$$A_5 = \begin{bmatrix} 1 & 1 & 1 & 1 & 9 & 1 & 1 & 9 & 9 & 1 & 1 & 9 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 9 \\ 1 & 1 & 1 & 1 & 9 & 1 & 1 & 9 & 9 & 1 & 1 & 9 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 9 \\ 1 & 1 & 1 & 1 & 9 & 1 & 1 & 9 & 9 & 1 & 1 & 9 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 9 \\ 1 & 1 & 1 & 1 & 9 & 1 & 1 & 9 & 9 & 1 & 1 & 9 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 9 \\ \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & 1 & \frac{1}{9} & \frac{1}{9} & 1 & 1 & \frac{1}{9} & \frac{1}{9} & 1 & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & 1 \\ 1 & 1 & 1 & 1 & 9 & 1 & 1 & 9 & 9 & 1 & 1 & 9 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 9 \\ 1 & 1 & 1 & 1 & 9 & 1 & 1 & 9 & 9 & 1 & 1 & 9 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 9 \\ \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & 1 & \frac{1}{9} & \frac{1}{9} & 1 & 1 & \frac{1}{9} & \frac{1}{9} & 1 & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & 1 \\ \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & 1 & \frac{1}{9} & \frac{1}{9} & 1 & 1 & \frac{1}{9} & \frac{1}{9} & 1 & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & 1 \\ 1 & 1 & 1 & 1 & 9 & 1 & 1 & 9 & 9 & 1 & 1 & 9 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 9 \\ 1 & 1 & 1 & 1 & 9 & 1 & 1 & 9 & 9 & 1 & 1 & 9 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 9 \\ 1 & 1 & 1 & 1 & 9 & 1 & 1 & 9 & 9 & 1 & 1 & 9 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 9 \\ 1 & 1 & 1 & 1 & 9 & 1 & 1 & 9 & 9 & 1 & 1 & 9 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 9 \\ 1 & 1 & 1 & 1 & 9 & 1 & 1 & 9 & 9 & 1 & 1 & 9 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 9 \\ 1 & 1 & 1 & 1 & 9 & 1 & 1 & 9 & 9 & 1 & 1 & 9 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 9 \\ \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & 1 & \frac{1}{9} & \frac{1}{9} & 1 & 1 & \frac{1}{9} & \frac{1}{9} & 1 & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & 1 \\ \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & 1 & \frac{1}{9} & \frac{1}{9} & 1 & 1 & \frac{1}{9} & \frac{1}{9} & 1 & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & \frac{1}{9} & 1 \end{bmatrix} \quad (25)$$

Procedurom *AHP* metode, kako je objašnjeno u poglavlju 4.3.3. dolazi se do rješenja pojedinih matrica koja predstavljaju rezultate lokalnih prioriteta za navedeni kriterij. Rezultati lokalnih prioriteta su prikazani u sljedećim matricama, izraz (26), gdje se prvi redovi odnose na varijantu 1, drugi na varijantu 2, itd..

$$\begin{aligned}
A_1 = & \begin{bmatrix} 0,0299 \\ 0,0850 \\ 0,0103 \\ 0,0489 \\ 0,0978 \\ 0,0117 \\ 0,0115 \\ 0,0675 \\ 0,0577 \\ 0,0117 \\ 0,0264 \\ 0,1136 \\ 0,0768 \\ 0,0119 \\ 0,0780 \\ 0,0385 \\ 0,0429 \\ 0,0840 \\ 0,0120 \\ 0,0840 \end{bmatrix} ; \quad A_2 = \begin{bmatrix} 0,0587 \\ 0,1418 \\ 0,0774 \\ 0,0341 \\ 0,0341 \\ 0,0341 \\ 0,0631 \\ 0,0156 \\ 0,0332 \\ 0,0647 \\ 0,0350 \\ 0,0090 \\ 0,0350 \\ 0,0161 \\ 0,0354 \\ 0,0354 \\ 0,2115 \\ 0,0412 \\ 0,0083 \\ 0,0164 \end{bmatrix} ; \quad A_3 = \begin{bmatrix} 0,0148 \\ 0,0211 \\ 0,0517 \\ 0,0192 \\ 0,0198 \\ 0,0387 \\ 0,0892 \\ 0,1180 \\ 0,0533 \\ 0,0533 \\ 0,0148 \\ 0,0533 \\ 0,0148 \\ 0,0451 \\ 0,0148 \\ 0,0533 \\ 0,2019 \\ 0,0451 \\ 0,0387 \\ 0,0387 \end{bmatrix} ; \quad A_4 = \begin{bmatrix} 0,0310 \\ 0,1240 \\ 0,0128 \\ 0,0310 \\ 0,0533 \\ 0,0183 \\ 0,0799 \\ 0,0799 \\ 0,0310 \\ 0,0310 \\ 0,0533 \\ 0,0533 \\ 0,0183 \\ 0,0310 \\ 0,0310 \\ 0,0128 \\ 0,1678 \\ 0,0533 \\ 0,0069 \\ 0,0799 \end{bmatrix} ; \quad A_5 = \begin{bmatrix} 0,0643 \\ 0,0643 \\ 0,0643 \\ 0,0643 \\ 0,0071 \\ 0,0643 \\ 0,0643 \\ 0,0071 \\ 0,0071 \\ 0,0643 \\ 0,0643 \\ 0,0071 \\ 0,0643 \\ 0,0643 \\ 0,0643 \\ 0,0643 \\ 0,0643 \\ 0,0643 \\ 0,0643 \\ 0,0071 \end{bmatrix} \quad (26)
\end{aligned}$$

Pripadajuće težine pojedinih kriterija prikazane su u sljedećem obliku:

$$K_1 = [0,0610] ; \quad K_2 = [0,3700] ; \quad K_3 = [0,1380] ; \quad K_4 = [0,2120] ; \quad K_5 = [0,2180] \quad (27)$$

Uzimajući u obzir vrijednosti lokalnih prioriteta te pripadajućih vrijednosti težina pojedinih kriterija, pomoću izraza (28) dolazi se do ukupnih prioriteta pojedinih alternativa.

$$P_i = A_{1i} \cdot K_1 + A_{2i} \cdot K_2 + A_{3i} \cdot K_3 + A_{4i} \cdot K_4 + A_{5i} \cdot K_5 \quad (28)$$

gdje je:

- P_i - ukupni prioritet i-te alternative,
- A_{1i} - lokalni prioritet i-te alternative s obzirom na prvi kriterij,
- A_{2i} - lokalni prioritet i-te alternative s obzirom na drugi kriterij,

- A_{3i} - lokalni prioritet i-te alternative s obzirom na treći kriterij,
 A_{4i} - lokalni prioritet i-te alternative s obzirom na četvrti kriterij,
 A_{5i} - lokalni prioritet i-te alternative s obzirom na peti kriterij,
 K_{1-5} - vrijednost težine pojedinog kriterija

Konačni rezultati tj. ukupni prioriteti pojedinih alternativa prikazani su u slijedećoj matrici (29). Iz rezultata je vidljivo da varijanta 17 ima najveći iznos prioriteta, što znači da predstavlja projektno rješenje koje optimalno zadovoljava postavljene kriterije.

$$P_i = \begin{bmatrix} 0,046 \\ 0,102 \\ 0,053 \\ 0,038 \\ 0,034 \\ 0,036 \\ 0,068 \\ 0,044 \\ 0,031 \\ 0,053 \\ 0,042 \\ 0,031 \\ 0,038 \\ 0,033 \\ 0,041 \\ 0,039 \\ 0,160 \\ 0,051 \\ 0,025 \\ 0,035 \end{bmatrix} \begin{matrix} - VARIJANTA_1 \\ - VARIJANTA_2 \\ - VARIJANTA_3 \\ - VARIJANTA_4 \\ - VARIJANTA_5 \\ - VARIJANTA_6 \\ - VARIJANTA_7 \\ - VARIJANTA_8 \\ - VARIJANTA_9 \\ - VARIJANTA_10 \\ - VARIJANTA_11 \\ - VARIJANTA_12 \\ - VARIJANTA_13 \\ - VARIJANTA_14 \\ - VARIJANTA_15 \\ - VARIJANTA_16 \\ - VARIJANTA_17 \\ - VARIJANTA_18 \\ - VARIJANTA_19 \\ - VARIJANTA_20 \end{matrix} \quad (29)$$

5.4 FAZA 4 – Utvrđivanje stabilnosti projektirane varijante rasporeda proizvodnih površina postojećeg brodogradilišta analizom osjetljivosti

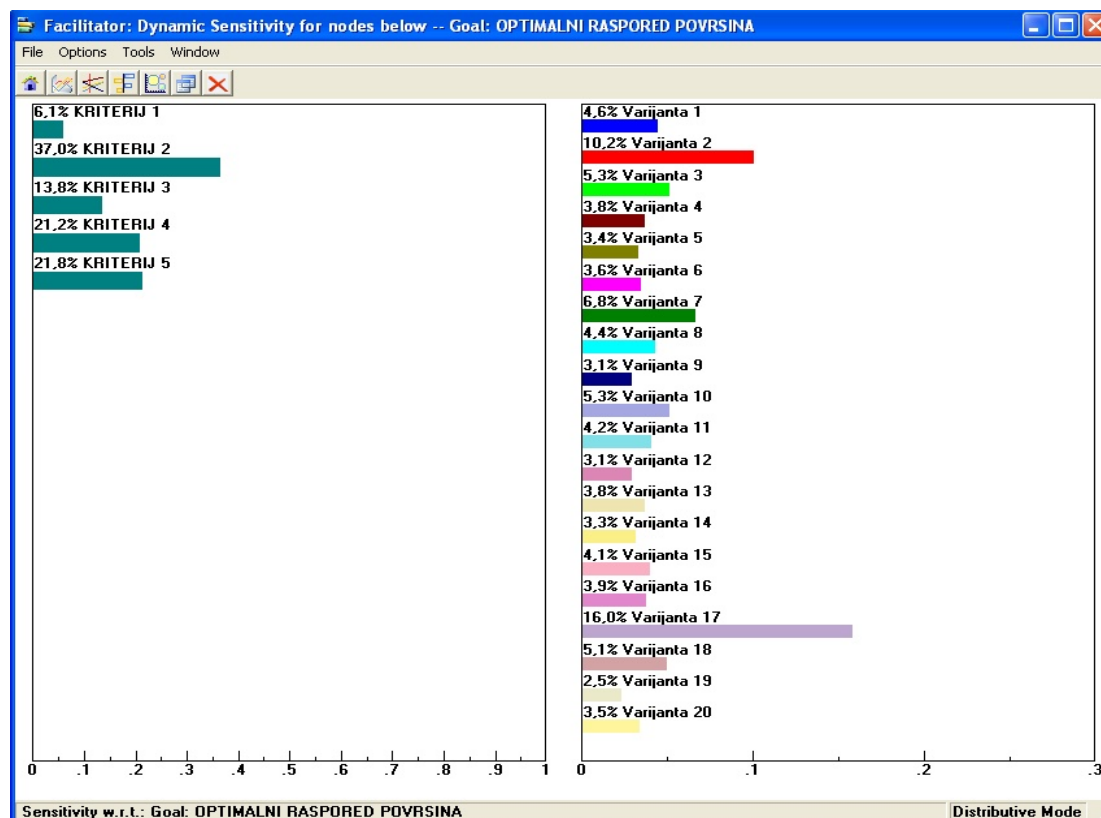
Kako je već opisano u poglavlju 4.4., utvrđivanje stabilnosti, a ovdje konačnih rezultata iz prethodne faze sa varijantom 17 kao optimalnim rješenjem, vrši se detaljnom analizom osjetljivosti. Analiza osjetljivosti na promatranom realnom problemu izvršena je s ciljem utvrđivanja da li bi spomenuti konačni rezultati bili drugačiji kada bi se prioriteti postavljenih kriterija mijenjali u određenim granicama. U tu svrhu vršile su se promjene ulaznih prioriteta kriterija prema većem broju scenarija, te su se pratili izlazni rezultati.

5.4.1 Dinamička analiza osjetljivosti


Provedbom dinamičke analize osjetljivosti (engl. *Dynamic Sensitivity Analysis*) prioriteti kriterija su se dinamički mijenjali u određenim intervalima te se je promatralo kako oni utječu na izlaznu rang ljestvicu. Zaključeno je da unatoč navedenim izmjenama prioriteta pojedinih kriterija, na način objašnjen u poglavlju 4.4, odabrana varijanta 17 s većom ili manjom prednosti uvijek predstavlja optimalno rješenje. Rezultati dinamičke analize prikazani su na slici 5.4.1.

5.4.2 Analiza izvedbene osjetljivosti

Prema slici 5.4.2. koja predstavlja rezultate analize izvedbene osjetljivosti (engl. *Performance Sensitivity*), moguće je zaključiti, praćenjem svijetlo ljubičaste linije, da odabrana varijanta 17 bitno prednjači prema drugom, trećem i četvrtom postavljenom kriteriju, dijeli prvo mjesto s većim brojem varijanti kod petog postavljenog kriterija, te da joj je jedina slabija točka prvi kriterij. Temeljem svih kriterija zajedno ona je hijerarhijski rangirana na prvom mjestu s desne strane promatrane slike.



Slika 5.4.1. Rezultati dinamičke analize osjetljivosti (odabrano stanje)




Slika 5.4.2. Rezultati analize izvedbene osjetljivosti

5.4.3 Analiza dijagramom stupnja osjetljivosti


Analizom dijagramom stupnja osjetljivosti, slike 5.4.3 do 5.4.7. može se očitati raspon intervala vrijednosti prioriteta pojedinog kriterija unutar kojega se pojedino alternativno projektno rješenje rasporeda proizvodnih površina smatra optimalnim.

Prema kriteriju 1, odnosno prema *SLP* ocjeni rasporeda površina iz slike 5.4.3. može se vidjeti da se odabrana varijanta 17 smatra optimalnom za vrijednost prvog kriterija od 0,061 (crvena vertikalna linija) te za svaku vrijednost tog kriterija u intervalu od 0 do 0,575. Kada bi vrijednost prvog kriterija bila veća od 0,575, u tom slučaju optimalno rješenje bio bi odabir varijante 2 sve do vrijednosti 0,727. Nadalje, za veće vrijednosti prioriteta prvog kriterija od 0,727 pa sve do vrijednosti 1, a što bi značilo da je to onda jedini postavljeni kriterij, optimalno rješenje bio bi odabir varijante 12. Međutim, konzultiranjem ekspertnog tima postojećeg brodogradilišta utvrđeno je da se, za razmatrani problem, vrijednost prioriteta ovog kriterija ne očekuje izvan prvog navedenog intervala.




Slika 5.4.3. Analiza dijagramom stupnja osjetljivosti na temelju kriterija 1

Zatim, prema kriteriju 2, tj. prema cijeni investicije, slika 5.4.4., može se vidjeti da se odabrana varijanta 17 smatra optimalnom za vrijednost prioriteta drugog kriterija od 0,37 (crvena vertikalna linija) te za svaku drugu vrijednost prioriteta tog kriterija u intervalu od 0 do 1.




Slika 5.4.4. Dijagram analize stupnja osjetljivosti na temelju kriterija 2

Analizom stupnja osjetljivosti na temelju trećeg te četvrtog kriterija, tj. kriterija o zadržavanju postojećih objekata u što je moguće većoj mjeri te kriterija o izvedivosti investicije u pogledu ometanja postojeće proizvodnje, prikazano na slici 5.4.5 i 5.4.6, može se također zaključiti da bez obzira na vrijednosti prioriteta ovih kriterija, varijanta 17 uvijek prednjači te se smatra optimalnom.




Slika 5.4.5. Dijagram analize stupnja osjetljivosti na temelju kriterija 3



Slika 5.4.6. Dijagram analize stupnja osjetljivosti na temelju kriterija 4

Nadalje, prema posljednjem, kriteriju 5, odnosno prema potrebi za širenjem izvan postojećih granica brodogradilišta, a što prema projektnom zadatku nije poželjno, iz slike 5.4.7. može se vidjeti da se odabrana varijanta 17 također smatra optimalnom za vrijednost prioriteta drugog kriterija od 0,218 (crvena vertikalna linija) te za svaku vrijednost prioriteta tog kriterija u intervalu od 0 do 1. Međutim, kada bi se promatrao samo taj kriterij, tj. za vrijednost prioriteta 1, tada je vidljivo da ukupno 15 razmatranih varijanti ne zahtijeva širenje izvan granica, dok njih 5 zahtijeva dodatne površine izvan brodogradilišta.




Slika 5.4.7. Dijagram analize stupnja osjetljivosti na temelju kriterija 5


5.4.4 Analiza dijagramom sučeljavanja

Nadalje je izvršena i analiza kroz dijagrame sučeljavanja (engl. *Head-to-Head Graph*) odabrane varijante 17 s ostalim varijantama, a na temelju postavljenih kriterija. Opis ove analize dan je u poglavlju 4.4.6.

Utvrđeno je, a kako je i vidljivo iz sljedećih slika od 5.4.8. do 5.4.26., da su svi ukupni prioriteti na strani odabrane varijante.




Slika 5.4.8. Dijagram sučeljavanja varijante 17 i varijante 1




Slika 5.4.9. Dijagram sučeljavanja varijante 17 i varijante 2

Varijanta 17 <> Varijanta 3




Slika 5.4.10. Dijagram sučeljavanja varijante 17 i varijante 3

Varijanta 17 <> Varijanta 4




Slika 5.4.11. Dijagram sučeljavanja varijante 17 i varijante 4


Varijanta 17 <> Varijanta 5




Slika 5.4.12. Dijagram sučeljavanja varijante 17 i varijante 5

Varijanta 17 <> Varijanta 6


Slika 5.4.13. Dijagram sučeljavanja varijante 17 i varijante 6

Varijanta 17 <> Varijanta 7


Slika 5.4.14. Dijagram sučeljavanja varijante 17 i varijante 7

Varijanta 17 <> Varijanta 8


Slika 5.4.15. Dijagram sučeljavanja varijante 17 i varijante 8

Varijanta 17 <> Varijanta 9

Slika 5.4.16. Dijagram sučeljavanja varijante 17 i varijante 9


Varijanta 17 <> Varijanta 10

Slika 5.4.17. Dijagram sučeljavanja varijante 17 i varijante 10

Varijanta 17 <> Varijanta 11


Slika 5.4.18. Dijagram sučeljavanja varijante 17 i varijante 11

Varijanta 17 <> Varijanta 12




Slika 5.4.19. Dijagram sučeljavanja varijante 17 i varijante 12

Varijanta 17 <> Varijanta 13




Slika 5.4.20. Dijagram sučeljavanja varijante 17 i varijante 13

Varijanta 17 <> Varijanta 14




Slika 5.4.21. Dijagram sučeljavanja varijante 17 i varijante 14

Varijanta 17 <> Varijanta 15




Slika 5.4.22. Dijagram sučeljavanja varijante 17 i varijante 15

Varijanta 17 <> Varijanta 16




Slika 5.4.23. Dijagram sučeljavanja varijante 17 i varijante 16


Varijanta 17 <> Varijanta 18



Slika 5.4.24. Dijagram sučeljavanja varijante 17 i varijante 18



Slika 5.4.25. Dijagram sučeljavanja varijante 17 i varijante 19



Slika 5.4.26. Dijagram sučeljavanja varijante 17 i varijante 20

5.5 Odabrano optimalno projektno rješenje kao podloga za osnivanje proizvodnih tokova

Provođenjem analize osjetljivosti, kao četvrte faze predložene metodologije za projektiranje optimalnog rasporeda proizvodnih površina brodogradilišta, potvrđeno je da su rezultati proizašli iz treće faze potpuno stabilni te konačni.

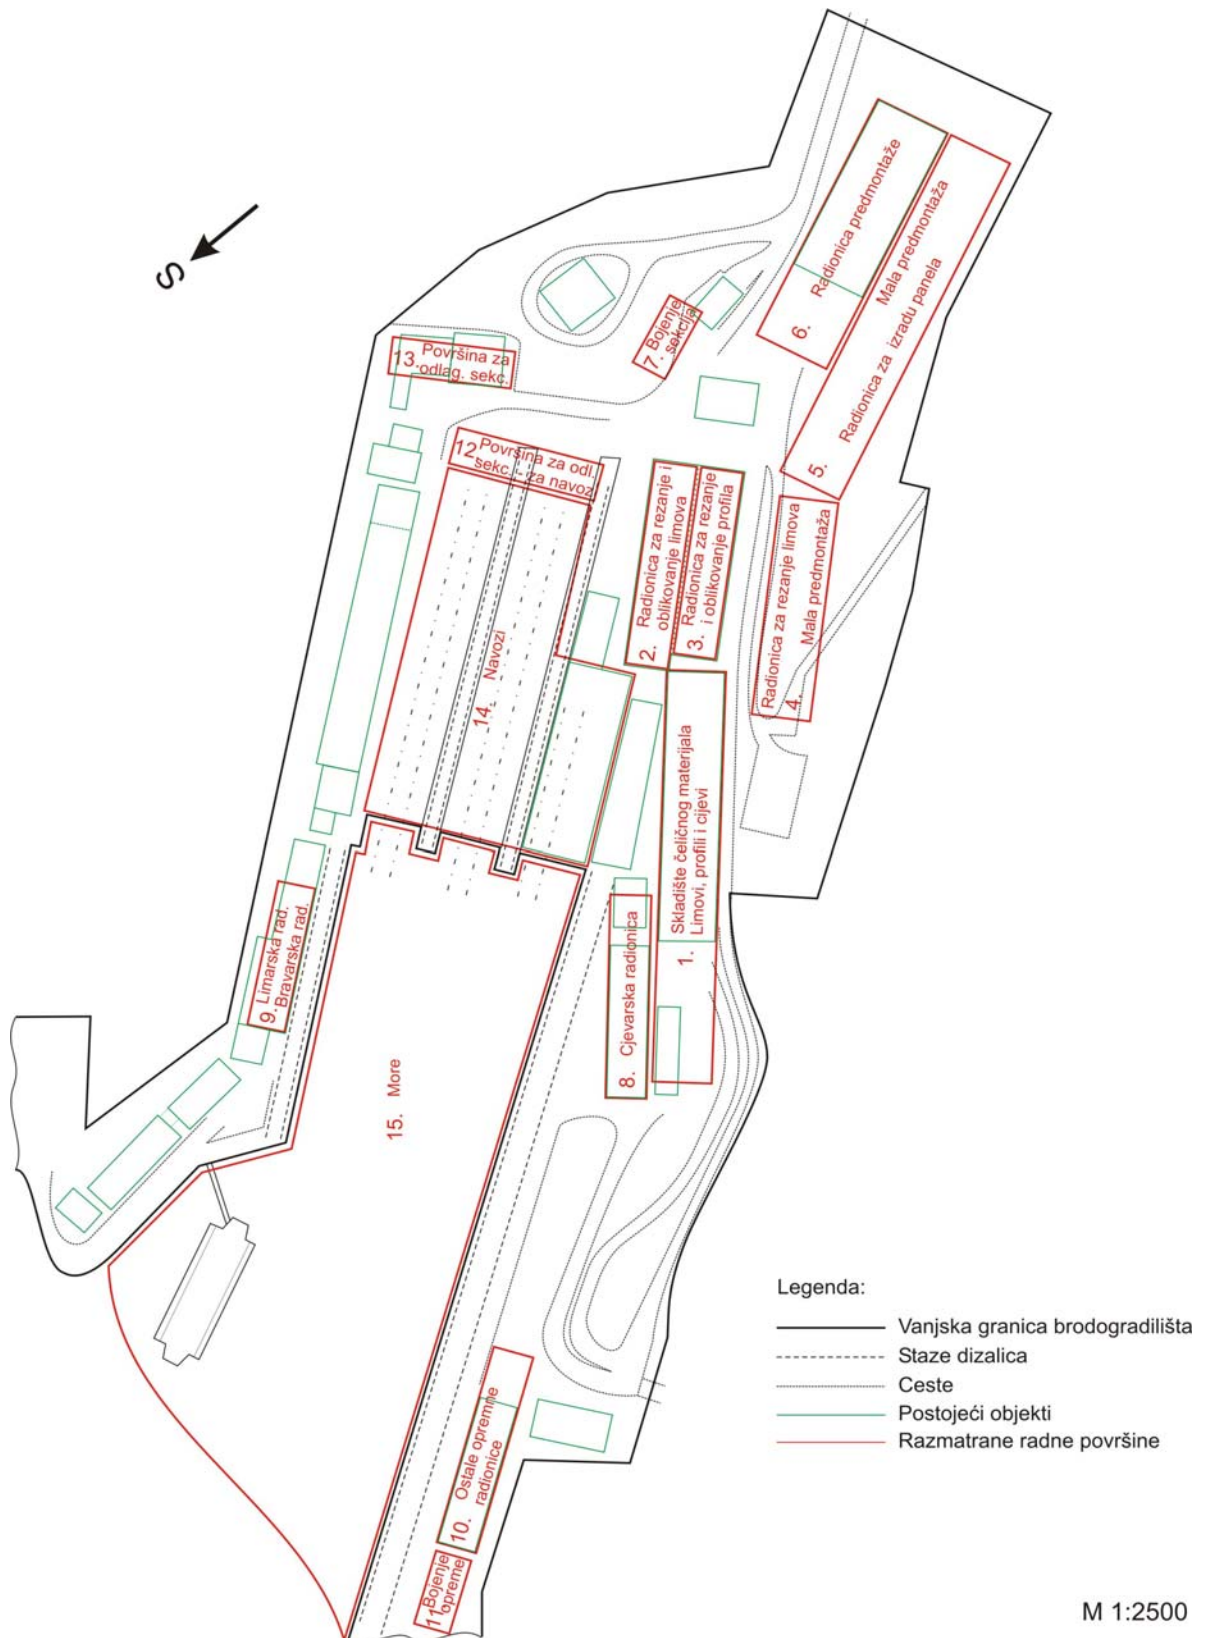
Navedeni rezultati, su radi lakšeg razumijevanja prikazani u obliku rang ljestvice, tablica 5.5.1.

Odabrano optimalno projektno rješenje jest varijanta 17. Prikaz te varijante koja optimalno zadovoljava pet postavljenih kriterija dan je na slici 5.5.1. gdje su u crvenoj boji prikazane odabrane proizvodne površine te je vidljiv njihov optimalni raspored u postojećim okvirima. Ovaj prikaz predstavlja podlogu za daljnju izradu detaljnih nacrti, ali i za osnivanje 3D virtualnog modela brodogradilišta što je vidljivo na slici 5.5.2. Na temelju izrađenog 3D modela moderniziranog brodogradilišta predlaže se primjena simulacijske metode kao bi se u okvirima virtualnog modela na računalu, u ranijoj fazi projektiranja i bez involviranja većih financijskih sredstava ispitala njegova propusnost za definirani proizvodni program.


Na istoj podlozi, kao optimalnom projektnom rješenju rasporeda proizvodnih površina postojećeg brodogradilišta, osnivan je prikaz osnovnih proizvodnih tokova brodograđevnog procesa. Navedeni tokovi temelje se na prethodno utvrđenom proizvodnom programu brodogradilišta te relevantnim zahtjevima i ograničenjima. Spomenuti proizvodni program prethodno je definiran u tablici 5.1.1., kao i pripadajući osnovni dijagram proizvodnog toka procesa koji je prikazan shematski na slici 5.1.1. Na slici 5.5.3. dan je prikaz odabranog rješenja s ucertanim osnovnim proizvodnim tokovima brodograđevnog procesa u obliku *Sankey* dijagrama, gdje debljina linije figurativno prikazuje količinu toka materijala, a boja prikazuje sastav.

Tablica 5.5.1. Rang ljestvica projektnih alternativa temeljena na ukupnim prioritetima

RED. BR.	ALTERNATIVE	UKUPNI PRIORITET
1.	<u>VARIJANTA 17</u>	<u>0,160</u>
2.	VARIJANTA 2	0,102
3.	VARIJANTA 7	0,068
4.	VARIJANTA 3	0,053
5.	VARIJANTA 10	0,053
6.	VARIJANTA 18	0,051
7.	VARIJANTA 1	0,046
8.	VARIJANTA 8	0,044
9.	VARIJANTA 11	0,042
10.	VARIJANTA 15	0,041
11.	VARIJANTA 16	0,039
12.	VARIJANTA 4	0,038
13.	VARIJANTA 13	0,038
14.	VARIJANTA 6	0,036
15.	VARIJANTA 20	0,035
16.	VARIJANTA 5	0,034
17.	VARIJANTA 14	0,033
18.	VARIJANTA 9	0,031
19.	VARIJANTA 12	0,031
20.	VARIJANTA 19	0,025



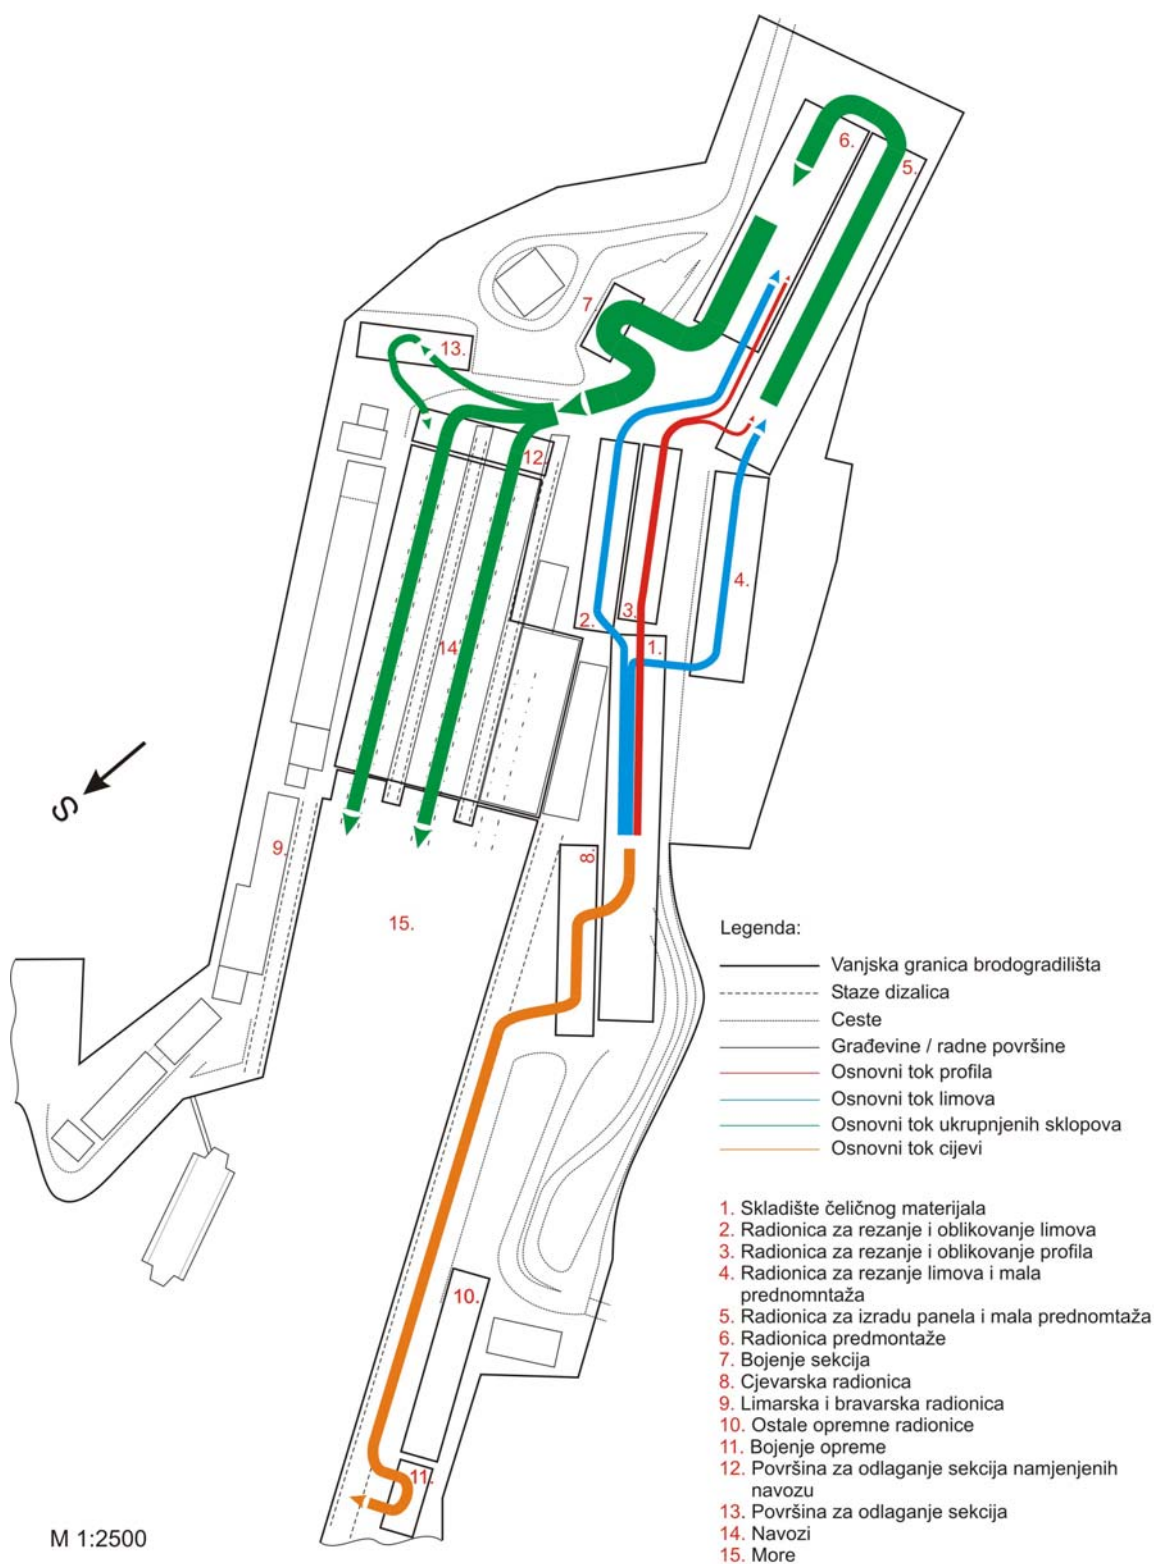
Slika 5.5.1. Prikaz optimalne varijante 17 rasporeda proizvodnih površina brodogradilišta



Slika 5.5.2. 3D virtualni prikaz optimalnog projektnog rješenja rasporeda proizvodnih površina moderniziranog postojećeg brodogradilišta

Legenda:

1. Glavno skladište čeličnog materijala
2. Radionica za rezanje i oblikovanje limova
3. Radionica za rezanje i oblikovanje profila
4. Radionica za rezanje limova
5. Radionica za izradu panela
6. Radionica predmontaže
7. Radionica za zrnčenje i bojenje gotovih sekcija
8. Radionica za rezanje, oblikovanje i opremanje cijevi
9. Bravarska i limarska radionica
10. Oprema obala i ostale opremne radionice
11. Radionica za zrnčenje i bojenje opreme
12. Površina za odlaganje/ukrupnjivanje gotovih sekcija
13. Površina za odlaganje sekcija prije montaže na navozu
14. Navoz
15. More



Slika 5.5.3. Proizvodni tokovi u obliku Sankey dijagrama, osnovani na odabranom optimalnom projektnom rješenju

Projektirani raspored proizvodnih površina predložen ovom metodologijom osnovan je na način da osnovni proizvodni tok kretanja čeličnog materijala od skladišta do izrade sekcija bude što je moguće više pravolinijski, nepovratan, te da postoji optimalan broj međuskladišta. Analizom se može utvrditi da isti opisno odgovara tehnološkoj razini broj 4 prema rasporedu površina i pripadajućem osnovnom proizvodnih tokova tablica 4.1.3 (Grupa E, Podgrupa E1).

Tok čeličnog materijala sa glavnog skladišta (poz. br.1) predviđen je u četiri smjera kako je vidljivo na slici 5.5.3, i to: prema radionici za rezanje i oblikovanje limova (poz. br. 2), radionici za rezanje i oblikovanje profila (pozicija br. 3), radionici za rezanje limova (poz. br. 4) i prema cjevarskoj radionici (poz. br. 8).

Radionica za rezanje i oblikovanje limova (poz. br. 2) te radionica za rezanje i oblikovanje profila (poz. br. 3) predviđene su u postojećim proizvodnim površinama, dok su radionica za rezanje limova (poz. br. 4) i cjevarska radionica (poz. br. 8) predviđene na novim.

Iz radionica nove radionice za rezanje limova (poz. br. 4) glavni tok čeličnog materijala prolazi kroz novu radionicu za izradu panela i elemenata male predmontaže (poz. br. 5), prema radionici predmontaže (poz. br.6).

Iz radionice predmontaže glavni tok čeličnog materijala kreće se kroz halu za bojenje sekcija (pozicija br. 7) prema površinama za opremanje sekcija (pozicija br.12 i br. 13), a potom na navoze (pozicija br. 14).

Nakon porinuća plovni objekt vezuje se uz opremnu obalu (pozicija br. 10) na kojoj su predviđene nove opremne radionice

Iz ucrtanih osnovnih proizvodnih tokova brodograđevnog procesa može se zaključiti da oni adekvatno slijede tehnoložnost suvremene gradnje broda bez povratnih tokova. Zaključeno potvrđuje i opravdava primjenu predložene metodologije na realnom problemu postojećeg brodogradilišta.

6. ZAKLJUČAK

Razvojem brodogradnje mijenjao se je tehnološki proces gradnje broda, kao i materijali za gradnju broda, rasla je proizvodnost, a sve je to zahtijevalo i drugačiju konfiguraciju brodogradilišta s novim, dodatnim radionicama i površinama. Odgovor na navedeni razvoj redovito se pronalazio u širenju oko već postojećih sadržaja. Takva rješenja su u određenim okolnostima bila zadovoljavajuća, ali ne i optimalna sa stajališta proizvodnih tokova procesa. U tom smislu, a naročito iz činjenice da su daljnja prostorna širenja postojećih brodogradilišta danas gotovo nemoguća, javlja se potreba za primjenom znanstvene metodologije u praćenju i otkrivanju mogućnosti poboljšanja brodograđevnog proizvodnog procesa kroz optimizaciju rasporeda postojećih površina, odnosno kroz unapređenje proizvodnih tokova.

Pretraživanjem dostupnih izvora informacija pristupilo se je analizi dosadašnjih istraživanja i spoznaja u projektiranju rasporeda površina. Locirana su područja primjene istog, te su zatim utvrđene primjenjive matematičke formulacije i tehnike projektiranja. Analizirani su suvremeni automatizirani alati za projektiranje rasporeda površina, kao i određene perspektivne metode i tehnike primijenjenih operacijskih istraživanja. Posebno je analiziran problem neodređenosti kod projektiranja rasporeda površina, te su utvrđena izvorišta istih i pristupi za njihovo upravljanje. Utvrđeno je da se za projektiranje rasporeda površina u području brodogradnje ne primjenjuju dovoljno suvremene metode, tehnike i alati. Stoga je, na temelju usvojenih saznanja, postavljen i cilj istraživanja, tj. osnivanje posebno prilagođene metodologije za projektiranje optimalnog rasporeda proizvodnih površina brodogradilišta. Dodatno, značajan napor uložen je pri odabiru i prilagodbi prikladnih metoda i alata, kako bi isti činili takvu metodologiju projektiranja rasporeda površina primjenjivom i učinkovitom te razumljivom i rukovodstvima brodogradilišta.

Ovako osnovana metodologija za projektiranje rasporeda proizvodnih površina, realizira se kroz utvrđenu proceduru koja se sastoji od četiri faze u okviru kojih se, za postizanje željenih rezultata koriste posebno prilagođene metode i alati.

U prvoj fazi prema osnovanoj metodologiji, provodi se utvrđivanje odnosa bliskosti relevantnih proizvodnih površina brodogradilišta. Navedeni odnosi bliskosti te njihovi pripadajući težinski faktori su utvrđeni metodom anketiranja značajnog broja istaknutih znanstvenih savjetnika i suradnika, te stručnjaka iz polja brodogradnje. Utvrđenim

odnosima bliskosti razmatranih proizvodnih površina, koji vrijede općenito za brodogradilišta, omogućeno je procjenjivanje u kojoj mjeri raspored razmatranih površina unutar brodograđevnog procesa zadovoljava saznanja o optimalnim proizvodnim tokovima.

Nadalje, u drugoj fazi, vrši se generiranje svih mogućih rješenja rasporeda razmatranih površina. Primjerice ako se razmatra petnaest proizvodnih površina tada postoji čak 15! mogućih alternativnih rješenja njihovog međusobnog razmještaja. Kao prikladno za generiranje alternativnih projektnih rješenja predloženo je korištenje pojednostavljene metode sistematskog planiranja rasporeda površina (engl. *Systematic Layout Planning*), a kroz specijalizirani računalski program *BlockPlan 1.5 for Windows* radi bržeg i lakšeg rada. Zatim, implementacijom utvrđenih odnosa bliskosti iz prve faze, u ovoj fazi je izvršeno ocjenjivanje svih generiranih alternativnih rješenja te je omogućeno njihovo rangiranje. Predložen je izbor reprezentativnog broja najizglednijih projektnih rješenja, među kojima se očekuje i optimalno.

U trećoj fazi, pristupa se utvrđivanju ciljne tehnološke razine te postavljenih projektnih zahtjeva i ograničenja relevantnih za projektiranje rasporeda proizvodnih površina razmatranog brodogradilišta. Zatim, na temelju utvrđenih kriterija i prethodno izabranih najizglednijih varijanti rješenja, pristupa se hijerarhijskom modeliranju konkretnog problema. Na najvišu hijerarhijsku razinu postavlja se cilj, odnosno optimalno projektno rješenje rasporeda proizvodnih površina brodogradilišta. Na prvu nižu hijerarhijsku razinu postavljaju se svi kriteriji, koje odabrane varijante, smještene ne najnižoj hijerarhijskoj razini, moraju zadovoljiti u funkciji cilja. Do izbora varijante, odnosno projektnog rješenja koje optimalno zadovoljava postavljene kriterije, dolazi se korištenjem metode analitičkog hijerarhijskog procesa (engl. *Analytic Hierarchy Process*). U tu svrhu izrađen je poseban alat za hijerarhijsko modeliranje u okviru *Microsoft Office Excel* programa, prilagođen problemu projektiranja rasporeda proizvodnih površina brodogradilišta, temeljen na formulacijama analitičkog hijerarhijskog procesa. Navedeni alat prilagođenim sučeljem olakšava provođenje procedure analitičkog hijerarhijskog procesa kod konkretnog problema te konačno omogućava izbor optimalnog projektnog rješenja rasporeda proizvodnih površina brodogradilišta.

U posljednjoj, četvrtoj fazi predlaže se utvrđivanje stabilnosti projektiranog rasporeda proizvodnih površina brodogradilišta primjenom analize osjetljivosti (engl. *Sensitivity Analysis*). Provede se četiri tipa empirijske analize osjetljivosti kako bi se odabrano projektno rješenje što pouzdanije provjerilo, i to: analiza izvedbene osjetljivosti,

analiza dinamičke osjetljivosti, analiza dijagramom stupnja osjetljivosti i analiza dijagramom sučeljavanja. Radi bolje izravne vizualizacije rezultata pri provođenju analize osjetljivosti predlaže se korištenje specijaliziranog računalskog paketa *Expert Choice*. U ovoj fazi, provjereni raspored proizvodnih površina brodogradilišta utvrđuje se kao konačno projektno rješenje i predstavlja podlogu za daljnju razradu te osnivanje proizvodnih tokova.

Predložena metodologija je zatim provjerena na realnom problemu kod postojećeg brodogradilišta, a u okviru projekta njegove tehnološke modernizacije. Utvrđena je početna tehnološka razina rasporeda površina istog koja je odgovarala tehnološkoj razini 2. Nakon primjene predložene metodologije, odabrano projektno rješenje unaprijedilo je raspored površina na tehnološku razinu 4 pri tom optimalno zadovoljavajući postavljene kriterije. Isto projektno rješenje je, u preliminarnoj fazi navedenog projekta tehnološke modernizacije, uzeto za daljnju razradu. Navedeni projekt prošao je recenziju od strane EU stručnjaka te je pozitivno ocijenjen, a što je dodatno opravdalo svrhu i doprinos predložene metodologije.

Nadalje, preporuča se daljnje istraživanje u svrhu prilagodbe te analize primjenjivosti predložene metodologije za projektiranje optimalnog rasporeda površina brodogradilišta na njegove odabrane dijelove. Preporuča se istražiti i utvrditi doprinos primjene ovakve metodologije kod unapređenja rasporeda i dimenzioniranja proizvodnih tokova, kao i podizanja tehnološke razine pojedinog proizvodnog procesa. Na taj način predložena metodologija bila bi primjenljiva globalno, odnosno na projektiranje rasporeda proizvodnih površina brodogradilišta u preliminarnoj fazi, a što je u ovom radu i dokazano, te lokalno, odnosno na projektiranje rasporeda radnih stanica unutar određene proizvodne površine kao posebnog dijela cjelokupnog brodograđevnog procesa. Zatim preporuča se analiza mogućnosti unapređenja same metodologije u okviru prve faze implementacijom tehnika i alata temeljenih na ekspertnom pristupu kako bi se u budućnosti umanjila potreba za provođenjem anketiranja relevantnih eksperata.

Popis literature

- [1]. Karray, F., E. Zanelidin, T. Hegazy, A.H.M. Shabeeb, and E. Elbelgati, "Tools of Soft Computing as Applied to the Problem of Facilities Layout Planning", *IEEE Transaction on Fuzzy Systems*, Vol. 8, No. 4, pp. 367-379, August 2000.
- [2]. Singh, N. and M.H. Wang, "Concurrent engineering in a high variety printing environment", *Int'l Journal of Production Research*, Vol. 32, No. 7, pp. 1675-1691, 1994.
- [3]. Marakas, G.M., "*Decision Support Systems*", Prentice Hall Inc., 2002.
- [4]. Turban, E., and J.E. Aronson, "*Decision Support Systems and Intelligent Systems*", 6th ed., Reading: Prentice Hall Inc., Upper Saddle River, NJ, 2001.
- [5]. Tommelein, I.D., "SightPlan: a Case Study of BB1", Section 5.5.1 in Sriram, R.D (ed.). *Intelligent Systems for Engineering: A Knowledge-Based Approach*. Springer Verlag, London, U.K, 1997.
- [6]. Tompkins, J.A., J.A. White, Y.A. Bozer, and J.M.A. Tanchoco, "*Facilities Planning*", 3rd Ed., Reading: John Wiley Inc., NY, 2002.
- [7]. Blair, E. L., and S. Miller, "An interactive approach to facilities design using microcomputers", *Journal of Computers in Industrial Engineering*, Vol. 9, pp. 91-102, 1985.
- [8]. Ligget, R.S., "Automated facilities layout: past present and future", *Automation in Construction*, Vol. 9, 197-215, 2000.
- [9]. Negnevitsky, M., "*Artificial Intelligence: A Guide to Intelligent Systems*", Pearson, Sydney, 2002.
- [10]. Lok, S. and Feiner, S., "A Survey of Automated Layout Techniques for Information Presentation", *Communications of ACM*, Vol. 41, No. 7, pp. 81-87, 1998.
- [11]. Ahmad, R. A., "*An Intelligent Expert System for Decision Analysis and Support in Multi-Attribute Layout Optimization*" University of Waterloo, Ontario, Canada, 2005.
- [12]. Saaty, T. L., „The Analytic Hierarchy Process“, ISBN: 0-07-054371-2. McGraw-Hill, Inc. USA, 1980.
- [13]. Muther, R. „*Sistematic Layout Planning*“, Second edition, ISBN: 0-933684-06-1. Menagement & Industrial Research Publications, USA, 1973.
- [14]. Epstein, S. L., B. Moulin, W. Chaker, J. I. Glasgow, J. Gancet, "Pragmatism and Spatial Layout Design", *COSIT 2001*, pp.189-205, 2001.
- [15]. Abdinnour-Helm, S., and Hadley, S.W., "Tabu search based heuristics for multi-floor facility layout", *Int'l Journal of Production Research*, Vol. 38, No. 2, pp. 365-383, 2000.

-
- [16]. Yang, T., and C. Kuo, "A Hierarchical AHP/DEA Methodology For The Facilities Layout Design Problem", *European Journal of Operational Research*, Vol. 147, pp. 128-136, 2003.
- [17]. Burke, E.K., Kendall, G., Whitwell, G., "A New Placement Heuristic for the Orthogonal Stock-Cutting Problem", *Operations Research*, Vol. 52, No. 4, pp. 665-671, 2004.
- [18]. Akoumianakis, D., Savidis, A., Stephanidis, C., "Encapsulating intelligent interactive behaviour in unified user interface artifacts", *Interacting with Computers*, Vol. 12, pp. 383-408, 2000.
- [19]. Youssef, H., S.M. Sait, and H. Ali, "Fuzzy Simulated Evolution Algorithm for VLSI Placement", *Computers & Industrial Engineering*, Vol. 44, pp. 227-247, 2003.
- [20]. Mir, M., and M.H. Imam, "Topology optimization of arbitrary-size blocks using bivariate formulation", *Journal of Computer Aided Design*, Vol. 24, No. 10, pp. 556-564, 1992.
- [21]. Siarry, P., L. Bergonzi, and D. Dreyfus, "Thermodynamic optimization of block placement", *IEEE Transaction on CAD*, Vol. 6, No. 2, pp. 211-221, 1987.
- [22]. Schnecke, V., and O. Vonberger, "Hybrid Genetic Algorithms for Constrained Placement Problems", *IEEE Transactions on Evolutionary Computation*, Vol. 1, no. 4, pp. 266-277, 1997.
- [23]. Cohoon, J.P., S.U. Hegde, W.N. Martin, and D.S. Richards, "Distributed genetic algorithms for floor-plan design problem", *IEEE Transactions On CAD*, Vol. 10, No. 4, pp. 483-492, 1991.
- [24]. Tam, K.Y., and S.G. Li, "A hierarchical approach to facility layout problem", *International Journal of Production Research*, Vol. 29, No. 1, pp. 165-184, 1991.
- [25]. Hassan, M.M.D., "Machine layout problem in modern manufacturing facilities", *International Journal of Production Research*, vol. 29, No. 6, pp. 1263-1278, 1991.
- [26]. Jakobs, S., "On genetic algorithms for packing of polygons", *European Journal of Operational Research*, Vol. 88, pp. 165-181, 1996.
- [27]. Moon, B.R., and Kim, C.K., "Dynamic embedding for genetic VLSI circuit partitioning", *Engineering Applications of Artificial Intelligence*, Vol. 11, pp. 67-76, 1998.
- [28]. Welgama, P.S., S. Palitha, and P.R. Gibson, "Computer-Aided Facility Layout – A Status Report", *International Journal of Advanced Manufacturing Technology*, Vol. 10, No. 1, pp. 66-77, 1995.
- [29]. Meller, R.D. and Gau, K.-Y., "The facility layout problem: recent and emerging trends and perspectives", *Journal of Manufacturing Systems*, Vol. 15, 351-366, 1996.
- [30]. Norman, B.A., and A.E. Smith, "Considering Uncertainty in Unequal Area Block Layout Design", citeseer.ist.psu.edu/271501.html, 2002.
-

-
- [31]. Murata, H., K. Fujiyoshi, S. Nakatake, and Y. Kajitani, "VLSI Module Placement Based on Rectangle-Packing by the Sequence-Pair", *IEEE Transactions on Computer-Aided Design Of Integrated Circuits And Systems*, Vol. 15, No. 12, December 1996.
- [32]. Khan, J.A., Sait, S.M., Minhas, M.R., "Fuzzy biasless Simulated Evolution for Multiobjective VLSI Placement", *IEEE, CEC2002*,. Honolulu, May 2002.
- [33]. McTear, M.F., 'Intelligent Interface Technology: From Theory to Reality', *Interacting with Computers*, Vol.12, pp. 323-336, 2000.
- [34]. Ngo, D.C.L., and B.L. Law, "An expert screen design and evaluation assistant that uses knowledge-based backtracking" *Information and Software Technology*, Volume 45, Issue 6, 15 April 2003, Pages 293-304.
- [35]. Ngo,D.C.L., "Measuring the aesthetic elements of screen designs" *Displays*, Vol.22, pp.73-78, 2001.
- [36]. Brusilovsky,P., "From adaptive hypermedia to adaptive Web", In P.Brusilovsky, M. T.Maybury (eds.), *Comm. of ACM* (Sp. Issue on the Adaptive Web), Vol.45, No.5, pp.31-33, 2002.
- [37]. Brusilovsky, P., "Adaptive hypermedia", *User Modeling and User Adapted Interaction*, Ten Year Anniversary Issue (Kobsa, A., ed.), Vol. 11, No. 1/2, pp. 87-110, 2001.
- [38]. Albrecht, D., Zukerman, I., Nicholson, A., "Bayesian Models for Keyhole Plan Recognition in an Adventure Game", *User Modeling and User-Adapted Interaction*, Vol. 8, pp. 5-47, 1999.
- [39]. Corbett, A., McLaughlin, M., Scarpinato, K.C., "Modeling Student Knowledge: Cognitive Tutors in High School and College", *User Modeling and User-Adapted Interaction*, Vol. 10, pp. 81-108, 2000.
- [40]. Wang, P. Y., Wascher, G., "Cutting and packing", *European Journal of Operational Research*, Volume 141, Issue 2, 1 September 2002, Pages 239-240.
- [41]. Kim, J.K., H.L.Kwang, and S.W. Yoo, "Fuzzy bin packing problem", *Fuzzy Sets and Systems*, Vol. 120, pp. 429-434, 2001.
- [42]. Dowsland, K.A., S. Vaid, and W.B. Dowsland, "An algorithm for polygon placement using a bottom-left strategy", *European J. of Operational Res.*, Vol. 141 (Sp. issue on cutting & packing), pp. 371-381, 2002.
- [43]. Wang, H., Huang, W., Zhang, Q., Xu, D., "An improved algorithm for the packing of unequal circles within a larger containing circle", *European Journal of Operational Research*, Vol. 141, pp. 440-453, 2002.
- [44]. Bozer, Y. A., and R. D. Meller, "A reexamination of the distance-based facility layout problem", *IEEE Transactions*, Vol. 29, No.7, pp. 549-560, 1997.
- [45]. Kusiak, A., and S.S. Heragu, "The Facility Layout Problem", *European Journal of Operational Research*, Vol. 29, pp. 229-251, 1987.
-

-
- [46]. Deb, S.K., and Bhattacharyya, B., "Fuzzy decision support system for manufacturing facilities planning", *Decision Support Systems*, to appear, 2004.
- [47]. Malakooti, B. and Tsurushima, A., "An expert system using priorities for solving multiple-criteria facility layout problems", *Int'l Journal of Production Research*, Vol. 27, No. 5, pp. 793-808, 1989.
- [48]. Irani, S., and Huang, H., "Custom Design of Facility Layouts for Multi-Product Facilities using Layout Modules", *IEEE Transactions on Robotics and Automation*, Vol. 16, pp. 259-267, 2000.
- [49]. Welgama, P.S., and P.R.Gibson, "A construction algorithm for a machine layout problem with fixed pickup and drop-off points", *Int'l Journal of Production Research*, Vol. 31, No. 11, pp. 2575-2590, 1993.
- [50]. Gloria, A. D., P. Faraboschi, and M. Olovieri, "Block placement with a Boltzman machine", *IEEE Transactions on CAD*, vol. 13, No. 6, pp.694-701, 1994.
- [51]. Pierce, J.F., and W.B. Crowston, "Tree search algorithms in quadratic assignment problems", *NavalResearch Logistics Quarterly*, Vol. 18, pp. 1-36, 1971.
- [52]. Kochenberger, A. G., McCarl, B. A, Wyman, F. P, "A Heuristic for General Integer Programming", *Decision Science*, Vol. 5, No. 1, pp. 36-44, 1974.
- [53]. Mak, K.L., Y.S. Wong and F.T.S. Chan, "A genetic algorithm for facility layout problems", *ComputerIntegrated Manufacturing Systems*, Vol. 11, No. 1-2, pp. 113-127, 1998.
- [54]. Foulds, L.R., "*Graph Theory Applications*", Springer Verlag, NY, 1995.
- [55]. Hower, W., "Placing Computations by Adaptive Procedures", *Artificial Intelligence in Engineering*, Vol. 11, pp. 307-317, 1997.
- [56]. Adya, S. N., Markov, I. L., and Villarrubia, P.G., "Improving Min-cut Placement for VLSI Using Analytical Techniques", *Proc. IBM ACAS Conference*, IBM ARL, February 2003, pp. 55-62.
- [57]. Mir, M., "Analytical technique for macrocell placement optimization with multiple constraints" *IEEE International Conference on Electronics, Circuits and Systems*, ICECS 2003, United Arab Emirates, pp. 503-506.
- [58]. Mir, M., and Imam, M.H. "A hybrid optimization approach for layout design of unequal-area facilities", *Computers and Industrial Engineering*, Vol. 39, 2001., pp. 49-63.
- [59]. Puchinger, J. and Raidl, G. R., "Models and Algorithms for Three-Stage Two-Dimensional Bin Packing", *Elsevier Science*, 30. November 2005.
- [60]. El-Bouri, A., N. Popplewell, S. Balakrishnan, and A. Alfa, "A Search Based Heuristic for Two Dimensional Bin-Packing Problem", *INFOR*, Vol. 32, No. 4, pp. 265-274, 1994.
- [61]. Hopper, E., and B.C.H. Turton, "An Empirical Investigation of meta-heuristic and heuristic algorithms for a 2D packing problem", *European Journal of Operational Research*, Vol. 128/1, pp. 34-57, 2000.
-

-
- [62]. Leung, T.W., C.K. Chan, M.D. Troutt, "Application of a mixed simulated annealing-genetic algorithm heuristic for the two-dimensional orthogonal packing problem", *European Journal of Operational Research*, Vol. 145, No. 3, pp. 530-542, 2003.
 - [63]. Liu, D., and H. Teng, "An Improved BL-Algorithm for Genetic Algorithm of the Orthogonal Packing of Rectangles", *European Journal of Operational Research*, Vol. 112, pp. 413-420, 1999.
 - [64]. Lodi, A., S. Martello, and D. Vigo, "Approximation algorithms for the oriented two-dimensional bin packing problem", *European Journal of Operational Research*, Vol. 112, pp. 158-166, 1999.
 - [65]. Martens, J., "Two genetic algorithms to solve a layout problem in fashion industry", *European Journal of Operational Research*, Vol. 154, pp. 304-322, 2004.
 - [66]. Adya, S. N., Markov, I. L., and Villarrubia, P.G., "Improving Min-cut Placement for VLSI Using Analytical Techniques", *Proc. IBM ACAS Conference*, IBM ARL, February 2003, pp. 55-62.
 - [67]. Souliah, A., "Simulated Annealing for manufacturing systems layout design", *European Journal of Operational Research*, Vol. 82, No. 3, pp. 592-614, 1995.
 - [68]. Ahmad, A.R., Basir, O.A., Hassanein, K., "Improved Placement Algorithm for Layout Optimization", *Proc. of the 2nd Int'l Industrial Engineering Conf. (IIEC'04)*, Dec. 2004, Riyadh, Saudi Arabia, 2004.
 - [69]. Lee, Y.H., and Lee, M. H., "A shape-based block layout approach to facility layout problem using hybrid genetic algorithm", *Computers and Industrial Engineering*, Vol. 42, pp. 237-248, 2002.
 - [70]. Youssef, H., S.M. Sait, and Adichi, H., "Evolutionary algorithms, Simulated Annealing and Tabu Search: A Comparative Study", *Engineering Applications of Artificial Intelligence*, Vol. 14, pp. 167-181, 2001.
 - [71]. Sait, M., El-Maleh, A., and Al-Abaji, R., "General Iterative Heuristic for VLSI Multiobjective Partitioning", *Proc. of the IEEE International Symposium on Circuits & Systems (ISCAS)*, V497-V500, 2003.
 - [72]. Goldberg, D.E., "*Genetic Algorithms in Search, Optimization, & Machine Learning*", Addison-Wesley Professional, 1989. ISBN-13: 978-0201157673.
 - [73]. Ahmad, A.R., Basir, O.A., Hassanein, K., "Intelligent Decision Support System for Layout Design", *Proc. of the 9th Asia-Pacific Decision Sciences Institute Conf. (APDSI'04)*, Seoul, Korea, July 2004.
 - [74]. Ahmad, A.R., Basir, O.A., Hassanein, K., "Decision Preferences, Constraints, and Evaluation Objectives in Layout Design: A Review of Modeling Techniques", *Proc. of the 5th Int'l Conf. on Operations and Quantitative Management (ICOQM-V)*, Oct. 2004, Seoul, Korea, 2004.
 - [75]. Baykasoglu, A., and N.N.Z. Gindy, "A Simulated Annealing Algorithm for Dynamic Layout Problem", *Computers & Operations Research*, Vol. 28, pp. 1403-1426, 2001.
-

-
- [76]. Ahmad, A.R., Basir, O.A., Hassanein, K., "Intelligent Decision Support System for Layout Design", *Proc. of the 9th Asia-Pacific Decision Sciences Institute Conf. (APDSI'04)*, Seoul, Korea, July 2004.
- [77]. Chung, Y-K., "A neuro-based expert system for facility layout construction", *Journal of Intelligent Manufacturing*, Vol. 10, No. 5, pp. 359-3856, 1999.
- [78]. Shore, R.H., Tompkins, J.A., "Flexible Facilities Design", *AIIE Transactions*, Vol. 12, pp. 200-25, 1980.
- [79]. Cheng, R., M. Gen, Tozawa, T., "Genetic Search for Facility Layout Design Under Interflows Uncertainty", *Japanese Journal of Fuzzy Theory and Systems*, Vol. 8, pp. 335-346, 1996.
- [80]. White, L. and A. Taket, "The Death of the Expert", *Journal of the Operational Research Society*, Vol. 45, pp. 733-748, 1994.
- [81]. Hower, W. and W. H. Graf, "A Bibliographical Survey of Constraint-based Approaches to CAD, Graphics, Layout, Visualization, and Related Topics", *Knowledge-Based Systems*, Vol. 9, No. 7, pp. 449-464, 1996.
- [82]. Hurst, "CobWeb: A Constraint based Web Browser", *ACSC-2003*, 2003.
- [83]. Graf, W., "The Constraint-Based Layout Framework LayLab and Its Applications", In: I. F. Cruz, J. Marks, K. Wittenburg, Eds., *Proc. of ACM Workshop on Effective Abstractions in Multimedia: Layout, Presentation, and Interaction*, San Francisco, CA, 1996.
- [84]. Hurst, N.; Marriott, K.; Moulder, P.; "Dynamic Approximation of Complex Graphical Constraints by Linear Constraints", *UIST-2002*.
- [85]. Heragu, S.S., *Facilities Design*, PWS Publishing, Boston, MA, 1997.
- [86]. Azadivar, F., and G. Tompkins, "Simulation Optimization with Quantitative Variables and Structural Model Changes: A Genetic Algorithm Approach", *European Journal of Operation Ressearch*, Vol. 113, pp. 169-182, 1999.
- [87]. Azadivar, F., and J. Wang, "Facility Layout Optimization using Simulation and Genetic Algorithms", *International Journal of Production Research*, Vol. 38, No. 17, pp. 4369-4383, 2000.
- [88]. Chan, F. T. S.; K. Abhary "Design and evaluation of automated cellular manufacturing systems with simulation modelling and AHP approach: a case study", *Integrated Manufacturing Systems.*, No. 7/8, pp. 39-52, 1996.
- [89]. Jameson, A., "Numerical uncertainty management in user and student modeling: An overview of systems and issues", *User Modeling and User-Adapted Interaction*, Vol. 5, pp. 193-251, 1996.
- [90]. Zukerman, I., Albrecht, D., "Predictive Statistical Models for User Modeling", *User Modeling and User Adapted Interaction*. Vol. 11, No. 1-2, pp. 5-18, 2001.
-

-
- [91]. Conati, C., Gertner, A., VanLehn, K., "Using Bayesian Networks to Manage Uncertainty in Student Modeling", *User Modeling and User-Adapted Interaction*, Vol. 12, pp. 371-417, 2002.
- [92]. Cordon, O., Gomide, F., Herrera, F., Hoffmann, F., Magdalena, "Ten years of genetic fuzzy systems: current framework and new trends", *Fuzzy Sets and Systems*, Vol. 141, pp. 5-31, 2004.
- [93]. Buffa, E.S., Armour, G.C., and Vollman, T.E., "Allocating facilities using CRAFT", *Harvard Business Review*, Vol. 42, 1964.
- [94]. Lee, R., J-M. Moore, "CORELAP-computerized relationship layout planning", *Journal of Industrial Engineering*, Vol. 18, No. 3, pp.195-200, 1967.
- [95]. Seehof, J.M., and Evans, W.O., "Automated layout design programme", *Journal of Industrial Eng.*, Vol. 18, No. 12, pp. 690-695, 1967.
- [96]. Johnson, D. S., M. R. Garey e F. R. K. Chung, "On packing two-dimensional bins", *SIAM J. Alg. Disc.Meth.* Vol. 3, pp. 66-76, 1982.
- [97]. Svestka, J.A., "MOCRAFT: a professional quality microcomputer implementation of craft with multiple objectives", *Computers & Industrial Engineering*, Vol. 18, No. 1, p. 13-22, 1990.
- [98]. Donaghey, C. E., and Pire, V. F., "Solving the facility layout problem with BLOCPLAN", *Industrial Engineering Department*, University of Houston, Houston, 1990.
- [99]. Montreuil, B., "A Modeling framework for Integrating Layout Design and Flow Network Design", *Proceedings of the Material Handling Research Colloquium*, Kentucky, pp. 43-58, 1991.
- [100]. Jojodia, S., Minis, I., Harhalakis, G., and Proth, J., "CLASS: Computerized Layout Solutions using Simulated Annealing", *International Journal of Production Research*, Vol. 30, No.1, pp. 95-108, 1992.
- [101]. Osman H.M., A., Georgy, M.E., Ibrahim, M.E., "A hybrid CAD-based construction site layout planning system using genetic algorithms", *Automation in Construction*, Vol. 12, pp. 749-764, 2003.
- [102]. Unigraphics Solutions Inc., "VisFactory and FactoryOpt", www.ugs.com, 2005.
- [103]. Balakrishnan, J., Cheng, C.H., Wong, K.F., "FACOPT: a user-friendly FACility layout OPTimization system", *Computers and Operations Research*, vol. 30, pages 1625-1641, 2003.
- [104]. Facilities Layout Design Software - VIP-PlanOpt, <http://planopt.com>. 2006.
- [105]. Sly, D., "Computerized Facilities Design and Management", *IIE Solutions*, pp. 43-51, 1995.
- [106]. Karray, F., De Silva, C., "Soft Computing and Intelligent Systems Design: Theory, Tools and Applications", Readings: Addison-Wesley, 2004.
-

-
- [107]. Kado, K., "An investigation of genetic algorithms for facility layout problems", *M.S. Thesis*, University of Edinburg, UK, 1995.
- [108]. Zha, X.F., and Lim, S.Y.E., "Intelligent design and planning of manual assembly workstations: A neurofuzzy approach", *Computers & Industrial Engineering*, Vol. 44, pp. 611-632, 2003.
- [109]. Nauck, D., F. Klawonn, and R. Kruse, "*Foundations of Neuro-Fuzzy Systems*", Wiley, 1997.
- [110]. Hirji, K.K., "Exploring Data Mining Implementation", *Comm. of ACM*, vol. 44, No. 7, pp. 87-93, 2001.
- [111]. Lamb, T. and Pires, F., "Questionnaire And Shipyard Visit Discussion Topics", Ship production research laboratory, University of michigan, 2008.
- [112]. A & P Appledore International, „Technology Survey”, U.K., 1991.
- [113]. Peters, A. B.; Yang, T., "Integrated Facility Layout And Meterial Handling System Design In Semiconductor Fabrication Facilities", *IEEE Transactions on Semiconductor Manufacturing*, vol. 10, No. 3, pp. 360-390, 1997.
- [114]. Murther, R.; Wheeler, J. D., "*Simplified Systematic Layout Planning*" Third edition, ISBN 0-933684-09-6; Menagement and Industrial Research Publications, Missouri, USA, 1994.
- [115]. Donaghey, E., C.; Chung, A., C.; Kong, H.; Pire, F., V., "*BlockPlan 1.5*", Department of Industrial Engineering, Cullen College of Engineering, University of Houston, USA, 2006.
- [116]. Horn, R.A. and Johnson, C.R., "*Matrix Analysis*", Cambridge University Press, UK, 1990 (chapter 8).
- [117]. Winston, W. L., "Operations Research: Applications and Algorithms", Publisher: Duxbury Press; 4 edition, ISBN: 0534380581. 2003.
- [118]. Hillier, F. S., Lieberman, G. J., "Introduction to operations research", 7th edition, McGraw Hill, ISBN 0072321695, 2001.
- [119]. Expert Choice, Inc., "Expert Choice software 11", Arlington, VA, USA, 2004.

Popis oznaka i kratica

POPIS OZNAKA

A	- isključivo potrebna bliskost
E	- potrebna bliskost
I	- važna bliskost
O	- neznatno važna bliskost
U	- nevažna bliskost
X	- nepoželjna bliskost
w_i	- težinski faktor za i -tu bliskost
ρ_{jk}	- ocjena bliskosti za i -tu bliskost od k -tog eksperta
m	- broj ocjena/eksperata
Y_i	- broj bliskosti u i -toj klasi
s	- ocjena rasporeda površina
n	- broj radnih površina
n	- broj elemenata koji se međusobno uspoređuju
a_{ij}	- numerički koeficijent <i>Saaty</i> -jeve skale
w_i	- težinski koeficijent i -tog elementa
w^T	- vektor približnih vrijednosti težinskih koeficijenata
λ_{\max}	- najveća svojstvena vrijednost matrice relativnih važnosti
CR	- stupanj konzistentnosti
CI	- indeks konzistentnosti
RI	- slučajni indeks
P_i	- ukupni prioritet i -te alternative,
A_{1i}	- lokalni prioritet i -te alternative s obzirom na prvi kriterij,
A_{2i}	- lokalni prioritet i -te alternative s obzirom na drugi kriterij,
A_{3i}	- lokalni prioritet i -te alternative s obzirom na treći kriterij,
A_{4i}	- lokalni prioritet i -te alternative s obzirom na četvrti kriterij,
A_{5i}	- lokalni prioritet i -te alternative s obzirom na peti kriterij,
K_{1-5}	- vrijednost težine pojedinog kriterija
S_x^F	- funkcija osjetljivosti
∂F	- promjena ciljne funkcije

POPIS KRATICA

<i>AHP</i>	- analitički hijerarhijski proces (engl. <i>Analytic Hierarchy process</i>)
<i>BIL</i>	- radionica s odjeljenjima za bravare i limare
<i>CI</i>	- cijena investicije kao kriterij
<i>DSS</i>	- sistem podrške pri donošenju odluke
<i>EU</i>	- Europska unija
<i>IZV</i>	- izvedivost investicije kao kriterij
<i>LNG</i>	- <i>liquefied natural gas</i> (ukapljeni prirodni plin)
<i>LPG</i>	- <i>liquefied petroleum gas</i> (ukapljeni petrolejski plin)
<i>MOT</i>	- radionica motorista
<i>NAV</i>	- površine za gradnju i predaju broda vodi
<i>OD1</i>	- površina za odlaganje/ukrupnjivanje sekcija
<i>OD2</i>	- površina za odlaganje gotovih sekcija
<i>P</i>	- proizvod
<i>PAN</i>	- radionica za izradu panela + mala predmontaža
<i>Q</i>	- količina
<i>R</i>	- tokovi
<i>RIC</i>	- radionica za rezanje i oblikovanje cijevi
<i>ROL</i>	- radionica za rezanje i oblikovanje limova
<i>ROP</i>	- radionica za rezanje i oblikovanje profila
<i>RPM</i>	- radionica predmontaže
<i>RRL</i>	- radionica za rezanje limova
<i>S</i>	- podrška
<i>SEA</i>	- površina mora na prostoru brodogradilišta
<i>SIG</i>	- Širenje izvan postojećih granica brodogradilišta kao kriterij
<i>SKL</i>	- glavno skladište čeličnog materijala
<i>SLP</i>	- sistematsko planiranje rasporeda površina (engl. <i>Systematic Layout Planning</i>)
<i>SOL</i>	- <i>SLP</i> ocjena rasporeda površina kao kriterij
<i>T</i>	- vrijeme
<i>VLCC</i>	- <i>very large crude carrier</i>
<i>ZBO</i>	- radionica za zrnčenje i bojenje opreme
<i>ZIB</i>	- radionica za zrnčenje i bojenje gotovih sekcija
<i>ZPO</i>	- Zadržavanje postojećih objekata kao kriterij

Popis slika

Slika 4.1. Blok dijagram predložene metodologije.....	36
Slika 4.1.1. Prikaz brodogradilišta s označenim osnovnim proizvodnim površinama.....	40
Slika 4.2.1. <i>SLP</i> procedura.....	49
Slika 4.2.2. Osnovni podaci o razmatranim proizvodnim površinama.....	51
Slika 4.2.3. Matrica odnosa bliskosti ispunjena podacima proizašlih iz prve faze.....	53
Slika 4.2.4. Izlazno radno sučelje s pojednostavljenim prikazom rasporeda površina.....	54
Slika 4.3.1. Hijerarhijska struktura <i>AHP</i> metode.....	59
Slika 4.3.2. Opći hijerarhijski model <i>AHP</i> metode.....	60
Slika 4.3.3. Izračun omjera težina kriterija unutar prilagođenog <i>AHP</i> alata	67
Slika 4.3.4. Izračun lokalnih prioriteta s obzirom na pojedine kriterije unutar prilagođenog <i>AHP</i> alata.....	69
Slika 4.3.5. Izračun ukupnih prioriteta unutar prilagođenog <i>AHP</i> alata.....	70
Slika 4.4.1. Prikaz zaslona pri izvođenju dinamičke analize osjetljivosti, slč. 1.....	75
Slika 4.4.2. Prikaz zaslona pri izvođenju dinamičke analize osjetljivosti, slč. 2.....	75
Slika 4.4.3. Prikaz zaslona pri analizi izvedbene osjetljivosti.....	76
Slika 4.4.4. Prikaz zaslona pri analizi dijagramom stupnja osjetljivosti.....	77
Slika 4.4.5. Prikaz dijagrama sučeljavanja varijante 2 i varijante 8.....	78
Slika 5.1.1. Prikaz zatečenog stanja postojećeg brodogradilišta.....	83
Slika 5.1.2. Shematski prikaz osnovnog brodograđevnog proizvodnog procesa.....	88
Slika 5.2.1. Prikaz varijante 1 generirane <i>SLP</i> metodom.....	91
Slika 5.2.2. Prikaz varijante 2 generirane <i>SLP</i> metodom.....	92
Slika 5.2.3. Prikaz varijante 3 generirane <i>SLP</i> metodom.....	93
Slika 5.2.4. Prikaz varijante 4 generirane <i>SLP</i> metodom.....	95
Slika 5.2.5. Prikaz varijante 5 generirane <i>SLP</i> metodom.....	95
Slika 5.2.6. Prikaz varijante 6 generirane <i>SLP</i> metodom.....	97
Slika 5.2.7. Prikaz varijante 7 generirane <i>SLP</i> metodom.....	98
Slika 5.2.8. Prikaz varijante 8 generirane <i>SLP</i> metodom.....	99
Slika 5.2.9. Prikaz varijante 9 generirane <i>SLP</i> metodom.....	100
Slika 5.2.10. Prikaz varijante 10 generirane <i>SLP</i> metodom.....	101
Slika 5.2.11. Prikaz varijante 11 generirane <i>SLP</i> metodom.....	103
Slika 5.2.12. Prikaz varijante 12 generirane <i>SLP</i> metodom.....	104

Slika 5.2.13. Prikaz varijante 13 generirane <i>SLP</i> metodom.....	105
Slika 5.2.14. Prikaz varijante 14 generirane <i>SLP</i> metodom.....	106
Slika 5.2.15. Prikaz varijante 15 generirane <i>SLP</i> metodom.....	107
Slika 5.2.16. Prikaz varijante 16 generirane <i>SLP</i> metodom.....	109
Slika 5.2.17. Prikaz varijante 17 generirane <i>SLP</i> metodom.....	110
Slika 5.2.18. Prikaz varijante 18 generirane <i>SLP</i> metodom.....	111
Slika 5.2.19. Prikaz varijante 19 generirane <i>SLP</i> metodom.....	112
Slika 5.2.20. Prikaz varijante 20 generirane <i>SLP</i> metodom.....	113
Slika 5.3.1. Međusobni odnosi vrijednosti osnovnih karakteristika alternativa.....	118
Slika 5.3.2. <i>AHP</i> model, hijerarhijska struktura realnog problema.....	120
Slika 5.4.1. Rezultat dinamičke analize osjetljivosti.....	133
Slika 5.4.2. Rezultat analize izvedbene osjetljivosti.....	133
Slika 5.4.3. Dijagram analize stupnja osjetljivosti na temelju kriterija 1.....	134
Slika 5.4.4. Dijagram analize stupnja osjetljivosti na temelju kriterija 2.....	135
Slika 5.4.5. Dijagram analize stupnja osjetljivosti na temelju kriterija 3.....	136
Slika 5.4.6. Dijagram analize stupnja osjetljivosti na temelju kriterija 4.....	136
Slika 5.4.7. Dijagram analize stupnja osjetljivosti na temelju kriterija 5.....	137
Slika 5.4.8. Dijagram sučeljavanja varijante 17 i varijante 1.....	138
Slika 5.4.9. Dijagram sučeljavanja varijante 17 i varijante 2.....	138
Slika 5.4.10. Dijagram sučeljavanja varijante 17 i varijante 3.....	139
Slika 5.4.11. Dijagram sučeljavanja varijante 17 i varijante 4.....	139
Slika 5.4.12. Dijagram sučeljavanja varijante 17 i varijante 5.....	139
Slika 5.4.13. Dijagram sučeljavanja varijante 17 i varijante 6.....	140
Slika 5.4.14. Dijagram sučeljavanja varijante 17 i varijante 7.....	140
Slika 5.4.15. Dijagram sučeljavanja varijante 17 i varijante 8.....	140
Slika 5.4.16. Dijagram sučeljavanja varijante 17 i varijante 9.....	141
Slika 5.4.17. Dijagram sučeljavanja varijante 17 i varijante 10.....	141
Slika 5.4.18. Dijagram sučeljavanja varijante 17 i varijante 11.....	141
Slika 5.4.19. Dijagram sučeljavanja varijante 17 i varijante 12.....	142
Slika 5.4.20. Dijagram sučeljavanja varijante 17 i varijante 13.....	142
Slika 5.4.21. Dijagram sučeljavanja varijante 17 i varijante 14.....	142
Slika 5.4.22. Dijagram sučeljavanja varijante 17 i varijante 15.....	143
Slika 5.4.23. Dijagram sučeljavanja varijante 17 i varijante 16.....	143

Slika 5.4.24. Dijagram sučeljavanja varijante 17 i varijante 18.....	143
Slika 5.4.25. Dijagram sučeljavanja varijante 17 i varijante 19.....	144
Slika 5.4.26. Dijagram sučeljavanja varijante 17 i varijante 20.....	144
Slika 5.5.1. Prikaz optimalne varijante 17 rasporeda proizvodnih površina brodogradilišta	147
Slika 5.5.2. 3D virtualni prikaz optimalnog projektnog rješenja rasporeda proizvodnih površina moderniziranog postojećeg brodogradilišta.....	148
Slika 5.5.3. Proizvodni tokovi u obliku Sankey dijagrama, osnovani na odabranom optimalnom projektnom rješenju.....	149
Slika P1.1. Anketni upitnik.....	174
Slika P2.1. Unos odabranih segmenata proizvodnog procesa.....	179
Slika P2.2. Unos međusobnih kodova bliskosti dobivenih metodom anketiranja.....	180
Slika P2.3. Definiranje težinskih faktora za pojedine kodove bliskosti.....	180
Slika P2.4. Generirane najizglednije projektne alternative, tj. varijante od 1 do 4.....	181
Slika P2.5. Generirane najizglednije projektne alternative, tj. varijante od 5 do 8.....	182
Slika P2.6. Generirane najizglednije projektne alternative, tj. varijante od 9 do 12.....	183
Slika P2.7. Generirane najizglednije projektne alternative, tj. varijante od 12 do 16.....	184
Slika P2.8. Generirane najizglednije projektne alternative, tj. varijante od do 20.....	185

Popis tablica

Tablica 2.1. Prosječne ocjene pristupa za upravljanje neodređenostima kod projektiranja rasporeda površina prema kriterijima evaluacije [11]....	23
Tablica 4.1.1. Tehnološke razine brodogradilišta, [111].....	37
Tablica 4.1.2. Podjela Grupe E na pripadajuće podgrupe.....	38
Tablica 4.1.3. Opis tehnoloških razina podgrupe E1.	39
Tablica 4.1.4. Pokazatelji odnosa bliskosti.....	43
Tablica 4.1.5. Predloženi težinski faktori pojedinih oznaka bliskosti.....	44
Tablica 4.3.1. Tehnološka raščlamba na grupe i podgrupe... ..	56
Tablica 4.3.2. <i>Saaty</i> -jeva skala vrednovanja.....	61
Tablica 4.3.3. Slučajni indeksi.....	65
Tablica 5.1.1. Zahtijevani proizvodni program promatranog brodogradilišta, varijanta A.....	85
Tablica 5.1.2. Zahtijevani proizvodni program promatranog brodogradilišta, varijanta B.....	86
Tablica 5.1.3. Zahtijevani proizvodni program promatranog brodogradilišta, varijanta C.....	86
Tablica 5.1.4. Ulazni podaci o radnim površinama.....	87
Tablica 5.1.3. Matrica odnosa bliskosti.....	89
Tablica 5.1.4. Težinski faktori oznaka bliskosti.....	89
Tablica 5.2.1. <i>SLP</i> ocjene rasporeda površina najizglednijih varijanti.....	90
Tablica 5.3.1. Osnovne karakteristike alternativa prema postavljenim kriterijima....	117
Tablica 5.3.2. Omjeri težina kriterija.....	121
Tablica 5.3.3. Vrijednosti težina kriterija.....	122
Tablica 5.5.1. Rang ljestvica projektnih alternativa temeljena na ukupnim prioritetima.....	146
Tablica P1.1. Rezultati odnosa bliskosti iz provedenog anketnog upitnika.....	175
Tablica P1.2. Rezultati težinskih faktora odnosa bliskosti	177
Tablica P3.1. Procjena omjera težina kriterija uspoređivanjem u parovima korištenjem <i>Saaty</i> -jeve skale s izračunom prioriteta <i>AHP</i> metodom.....	187
Tablica P3.2. Usporedba alternativa u parovima korištenjem <i>Saaty</i> -jeve skale prema kriteriju br. 1 s izračunom pripadajućih lokalnih prioriteta <i>AHP</i> metodom.....	188
Tablica P3.3. Usporedba alternativa u parovima korištenjem <i>Saaty</i> -jeve skale prema kriteriju br. 2 s izračunom pripadajućih lokalnih prioriteta <i>AHP</i> metodom.....	189

Tablica P3.4. Usporedba alternativa u parovima korištenjem Saaty-jeve skale prema kriteriju br. 3 s izračunom pripadajućih lokalnih prioriteta <i>AHP</i> metodom.....	190
Tablica P3.5. Usporedba alternativa u parovima korištenjem Saaty-jeve skale prema kriteriju br. 4 s izračunom pripadajućih lokalnih prioriteta <i>AHP</i> metodom.....	191
Tablica P3.6. Usporedba alternativa u parovima korištenjem Saaty-jeve skale prema kriteriju br. 5 s izračunom pripadajućih lokalnih prioriteta <i>AHP</i> metodom.....	192
Tablica P3.7. Izračun ukupnih prioriteta na temelju prioriteta kriterija i lokalnih prioriteta <i>AHP</i> metodom.....	193

Popis priloga

- PRILOG 1: Prikaz te obrada prikupljenih podataka o pokazateljima odnosa bliskosti metodom anketiranja značajnog broja relevantnih eksperata
- PRILOG 2: *Blockplan 1.5 software for Windows*: ulazni parametri te izlazni rezultati kao prikaz najizglednijih projektnih alternativa
- PRILOG 3: *AHP* metoda: Tablični prikaz dobivenih lokalnih i ukupnih prioriteta pomoću razvijenog prilagođenog alata za hijerarhijsko modeliranje u *Microsoft Excel*-u

Prilog 1.

Prikaz te obrada prikupljenih podataka o pokazateljima odnosa bliskosti metodom
anketiranja značajnog broja relevantnih eksperata

ANKETNI UPITNIK

Metoda anketiranja provedena je korištenjem prikazanog upitnika među relevantnim znanstvenim savjetnicima i suradnicima, te stručnjacima iz razmatranog polja brodogradnje (ekspertima) koji su bili dostupni u velikim hrvatskim brodogradilištima i fakultetima brodogradnje.

KOD	Bliskost (opis koda)	SLP oznaka
5	Isključivo potrebno	A
4	Posebno važno	E
3	Važno	I
2	Neznatno Važno	O
1	Nevažno	U
0	Nepoželjno	X

1. GLAVNO SKLADIŠTE, LIMOVI, PROFILI I CIJEVI	1
2. RADIONICA ZA REZANJE I OBLIKOVANJE LIMOVA (Al. + č. namjenjen oblikovanju)	2
3. RADIONICA ZA REZANJE I OBLIKOVANJE PROFILA	3
4. RADIONICA ZA REZANJE LIMOVA (Svi č. limovi koji nisu namjenjeni oblikovanju)	4
5. RADIONICA ZA IZRADU PANELA (s dodatnim površinama za malu predmontažu)	5
6. RADIONICA PREDMONTAŽE	6
7. RADIONICA ZA ZRNČENJE I BOJENJE GOTOVIH SEKCIJA	7
8. CJEVARSKA RADIONICA	8
9. ZAJEDNIČKA RADIONICA S ODJELJENJIMA ZA LIMARE I BRAVARE	9
10. OPREMNA OBALA I OSTALE OPREMNE RADIONICE	10
11. RADIONICA ZA ZRNČENJE I BOJENJE OPREME	11
12. POVRŠINA za odlaganje i ukupnjivanje sekcija namjenjenih montaži na navozu	12
13. POVRŠINA za odlaganje sekcija	13
14. NAVOZI	14
15. MORE (brodogradilište u uvali)	15

PRIMJER:

Odnos bliskosti između 1 i 3
(upisati KOD)

Slika P1.1. Anketni upitnik

Brojčani simboli upisani svijetlo plavom bojom unutar pojedinih polja anketnog upitnika predstavljaju oznaku pozicije. Npr. brojčani simbol 7-13 označava polje u kojemu se određuje odnos bliskosti među radnim površinama 7 i 13.

Tablica P1.1. Rezultati odnosa bliskosti iz provedenog anketnog upitnika

POZICIJA U TABLICI BLISKOSTI	EKSPERT 1	EKSPERT 2	EKSPERT 3	EKSPERT 4	EKSPERT 5	EKSPERT 6	EKSPERT 7	EKSPERT 8	EKSPERT 9	EKSPERT 10	EKSPERT 11	EKSPERT 12	EKSPERT 13	EKSPERT 14	EKSPERT 15	EKSPERT 16	ODABRANI KOD	OZNAKA BLISKOSTI
1-2	5	5	5	5	5	5	5	5	4	5	4	5	5	5	5	4	5	A
1-3	5	5	5	5	4	5	5	5	3	5	4	5	5	5	5	4	5	A
1-4	5	5	5	5	4	5	5	5	4	5	4	5	5	4	5	4	5	A
1-5	1	1	4	1	4	1	3	2	2	1	1	3	2	4	2	2	2	O
1-6	1	2	3	1	4	1	3	2	2	1	1	3	2	3	2	2	2	O
1-7	1	1	1	0	3	1	1	1	1	1	1	0	1	1	1	2	1	U
1-8	4	5	5	5	5	5	4	4	1	4	4	5	3	3	5	3	4	E
1-9	2	3	5	5	4	1	3	2	0	2	2	1	1	0	1	2	2	O
1-10	3	3	4	2	4	1	1	2	0	1	2	1	1	1	1	3	2	O
1-11	1	2	1	0	5	1	4	3	0	1	3	0	1	1	1	1	2	O
1-12	1	1	2	1	3	1	3	1	0	1	1	0	1	1	1	4	1	U
1-13	1	1	1	0	3	1	1	1	0	1	1	0	1	1	1	3	1	U
1-14	1	1	1	0	1	1	1	0	0	0	1	1	1	1	2	2	1	U
1-15	4	4	1	0	4	5	5	3	3	3	3	3	5	4	4	2	3	I
2-3	2	1	5	1	5	3	2	4	3	5	5	5	5	4	1	1	3	I
2-4	3	3	4	1	3	1	3	3	4	5	5	2	5	4	1	1	3	I
2-5	1	1	5	3	4	1	5	4	2	4	4	3	5	3	1	3	3	I
2-6	4	5	5	4	5	1	4	3	2	4	3	4	5	3	5	3	4	E
2-7	1	1	3	0	3	1	1	2	1	1	1	0	2	1	1	2	1	U
2-8	1	1	1	0	1	1	1	1	1	1	1	0	1	1	1	1	1	U
2-9	1	2	1	3	3	1	1	0	1	1	2	1	1	1	1	1	1	U
2-10	1	2	1	1	1	1	1	0	1	1	1	1	1	1	1	3	1	U
2-11	1	1	1	0	1	1	1	1	1	1	1	0	1	1	1	1	1	U
2-12	2	3	2	2	3	1	2	1	1	1	1	1	2	1	1	3	2	O
2-13	1	3	2	1	2	1	1	0	1	1	1	1	2	1	1	2	1	U
2-14	1	3	2	1	2	1	2	0	1	1	1	3	1	1	3	2	2	O
2-15	1	1	1	1	2	1	1	0	1	1	1	0	1	1	1	1	1	U
3-4	3	1	4	1	3	1	2	3	3	3	4	1	3	3	3	3	3	I
3-5	5	5	5	5	4	5	5	4	2	5	5	4	5	4	5	3	4	E
3-6	5	5	4	4	4	5	4	3	2	3	3	3	5	4	3	3	4	E
3-7	1	1	3	0	2	1	1	2	1	1	1	0	1	1	1	2	1	U
3-8	1	1	1	0	1	1	1	1	1	1	1	0	1	1	1	2	1	U
3-9	1	2	2	2	1	1	1	1	1	4	3	1	3	1	1	2	2	O
3-10	1	3	1	1	1	1	1	0	1	1	1	1	1	2	2	3	1	U
3-11	1	1	1	0	3	1	1	0	1	1	1	0	1	1	1	2	1	U
3-12	1	3	3	1	3	1	2	0	1	1	1	1	1	3	1	2	2	O
3-13	1	3	2	1	3	1	1	0	1	1	1	1	1	1	1	1	1	U
3-14	1	3	2	1	3	1	1	0	1	1	1	2	2	1	2	1	1	U
3-15	1	1	1	1	1	1	1	1	1	1	1	0	1	4	1	1	1	U
4-5	5	5	5	4	4	5	5	4	2	5	5	5	5	4	5	5	5	A
4-6	4	5	5	4	5	5	4	3	2	5	4	5	5	4	2	4	4	E
4-7	1	1	3	0	1	1	1	2	1	1	1	1	2	1	1	2	1	U
4-8	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	U
4-9	1	2	2	2	3	1	1	0	1	2	1	1	3	1	1	2	2	O

nastavak Tablice P1.1.

4-10	1	3	2	1	1	1	1	2	1	1	0	1	1	1	2	3	1	U
4-11	1	1	1	0	3	1	1	1	1	1	1	1	1	1	1	2	1	U
4-12	1	3	3	2	2	1	3	0	1	2	1	2	1	1	1	2	2	O
4-13	1	3	3	1	2	1	1	0	1	1	1	2	1	1	1	2	1	U
4-14	1	3	3	1	3	1	3	1	1	1	1	1	2	1	2	1	2	O
4-15	1	1	1	1	2	1	1	1	1	1	1	0	1	1	1	1	1	U
5-6	5	5	5	5	5	5	5	5	3	5	5	5	5	5	4	5	5	A
5-7	1	5	3	2	2	1	3	1	3	3	4	4	4	3	5	2	3	I
5-8	2	3	2	0	1	1	1	1	1	1	1	1	3	1	1	1	1	U
5-9	2	3	3	0	1	1	1	0	1	1	1	1	3	1	3	2	2	O
5-10	2	3	3	0	1	1	2	0	1	1	1	1	2	1	1	3	1	U
5-11	1	2	2	0	2	1	1	0	1	1	1	1	1	1	1	1	1	U
5-12	2	3	3	1	4	1	2	1	2	2	2	3	3	3	3	5	3	I
5-13	1	2	3	1	2	1	3	2	1	3	3	3	3	3	3	1	2	O
5-14	1	3	3	1	1	1	4	2	1	1	2	3	2	3	3	4	2	O
5-15	1	1	1	0	2	1	2	0	1	1	1	1	1	1	1	4	1	U
6-7	4	5	5	5	4	5	5	4	4	5	5	5	5	5	4	5	4	A
6-8	3	5	5	3	4	3	2	2	2	4	4	4	5	3	3	2	3	I
6-9	4	5	4	3	3	1	1	2	2	2	3	2	5	2	3	2	3	I
6-10	4	5	3	0	5	1	4	3	2	2	2	1	3	3	1	4	3	I
6-11	3	3	3	0	4	1	1	1	3	1	2	1	3	3	3	2	2	O
6-12	3	5	5	4	5	3	5	4	2	5	4	5	4	3	3	4	4	E
6-13	4	5	5	4	5	3	5	4	1	4	4	4	4	3	3	5	4	E
6-14	4	5	4	1	5	2	5	3	2	3	4	5	3	2	2	4	3	I
6-15	1	1	1	0	2	1	4	0	1	1	2	2	3	1	1	5	2	O
7-8	1	1	3	0	4	1	1	1	0	1	1	1	3	1	1	3	1	U
7-9	1	1	2	0	3	1	1	2	0	1	1	1	3	1	1	1	1	U
7-10	1	1	4	0	4	1	1	1	2	1	1	1	1	1	1	4	2	O
7-11	1	2	1	0	3	1	1	2	2	2	2	2	1	1	1	1	3	O
7-12	3	4	5	4	4	3	4	4	2	3	4	4	5	4	5	4	4	E
7-13	3	4	5	5	4	3	1	4	1	3	4	4	5	4	5	4	4	E
7-14	3	3	5	1	4	3	3	4	2	2	3	5	5	4	4	5	4	E
7-15	1	1	0	0	3	1	3	1	1	1	1	0	1	1	1	4	1	U
8-9	3	5	2	2	4	3	4	3	4	3	2	2	4	3	5	2	3	I
8-10	4	5	4	3	5	5	4	4	2	4	3	5	5	3	2	4	4	E
8-11	5	5	3	5	2	5	5	4	2	4	5	5	4	4	4	4	4	E
8-12	4	5	4	3	4	3	3	1	2	4	3	3	3	4	3	4	3	I
8-13	4	4	3	3	4	3	1	2	1	1	2	4	3	1	3	3	3	I
8-14	4	4	4	4	4	3	4	3	2	1	1	3	3	3	2	3	3	I
8-15	1	1	3	4	3	5	2	3	1	1	2	4	5	1	1	3	3	I
9-10	4	5	5	3	4	5	3	4	3	3	3	5	5	4	3	4	4	E
9-11	4	5	5	4	3	5	2	4	3	3	4	2	4	4	2	3	4	E
9-12	3	5	3	3	4	3	1	3	2	2	2	2	3	1	3	2	3	I
9-13	4	4	2	3	4	3	1	3	1	1	1	2	3	1	3	2	2	O
9-14	4	4	5	4	3	3	1	3	2	1	1	3	3	3	3	3	3	I
9-15	1	1	3	4	1	3	1	4	1	1	1	2	5	1	1	2	2	O
10-11	4	5	5	3	0	3	3	4	3	3	2	3	4	3	2	4	3	I
10-12	3	5	4	3	4	3	1	3	2	2	1	1	1	3	1	3	3	I
10-13	4	4	3	1	4	3	4	2	1	1	1	1	1	1	1	3	2	O
10-14	4	4	4	4	4	2	3	3	2	1	1	3	1	3	1	2	3	I
10-15	1	1	5	4	5	5	5	4	1	5	4	5	5	1	5	2	4	E

nastavak Tablice P1.1.

11-12	4	5	3	0	4	5	1	2	2	4	3	1	1	2	2	4	3	I
11-13	4	4	4	0	4	5	1	3	2	2	3	1	1	2	2	3	3	I
11-14	4	4	5	1	3	3	1	3	4	3	2	3	1	2	2	2	3	I
11-15	1	1	0	1	0	2	1	4	1	2	3	0	2	1	1	2	1	U
12-13	4	5	5	4	5	3	5	4	3	4	4	2	0	1	1	4	3	I
12-14	5	5	5	5	5	5	5	5	4	4	3	5	5	3	5	4	5	A
12-15	1	1	3	0	4	3	5	1	4	1	1	3	1	1	2	4	2	O
13-14	5	5	5	4	5	3	5	5	4	4	4	3	5	3	4	4	4	E
13-15	1	1	3	0	4	3	4	1	4	1	1	3	1	1	2	4	2	O
14-15	5	5	5	5	5	5	5	4	5	5	5	5	5	5	5	5	5	A

Tablica P1.2. Rezultati težinskih faktora odnosa bliskosti iz provedenog anketnog upitnika

OCJENA BLISKOSTI	OZNAKA BLISKOSTI	EKSPERT 1	EKSPERT 2	EKSPERT 3	EKSPERT 4	EKSPERT 5	EKSPERT 6	EKSPERT 7	EKSPERT 8	EKSPERT 9	EKSPERT 10	EKSPERT 11	EKSPERT 12	EKSPERT 13	EKSPERT 14	EKSPERT 15	EKSPERT 16	ODABRANI TEŽINSKI FAKTOR
5	A	16	16	64	64	64	16	16	125	125	16	27	64	10	64	16	16	45
4	E	4	4	16	16	16	4	4	25	25	4	9	16	5	16	4	4	11
3	I	2	2	4	4	4	2	2	5	5	2	3	4	2	4	2	2	3
2	O	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
1	U	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	X	-16	-16	-64	-64	-64	-16	-16	-125	-125	-16	-27	-64	-10	-64	-16	-16	-45

Prilog 2.

Blockplan 1.5 software for Windows: ulazni parametri te izlazni rezultati kao prikaz najizglednijih projektnih alternativa

a) Ulazni parametri

D:\TIN_MATULJA_PhD_2009.

Number	Department	Area
1	SKL	3520
2	ROL	1479
3	ROP	1360
4	RRL	2232
5	PAN	4480
6	RPM	3520
7	ZIB	540
8	RIC	1330
9	BIL	915
10	MOT	334
11	ZBO	300
12	OD1	784
13	OD2	1920
14	NAV	9350
15	SEA	10000

Average Area

Std. Dev. Area

Total Area

Slika P2.1. Unos odabranih segmenata proizvodnog procesa s zahtjevanim površinama

RELFORM

RELATIONSHIP CHART

		2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	SKL	A	A	A	O	O	U	E	O	O	O	U	U	U	I
2	ROL		I	I	I	E	U	U	U	U	U	O	U	O	U
3	ROP			I	E	E	U	U	O	U	U	O	U	U	U
4	RRL				A	E	U	U	O	U	U	O	U	O	U
5	PAN					A	I	U	O	U	U	I	O	O	U
6	RPM						A	I	I	I	O	E	E	I	O
7	ZIB							U	U	O	O	E	E	E	U
8	RIC								I	E	E	I	I	I	I
9	BIL									E	E	I	O	I	O
10	MQT										I	I	O	I	E
11	ZBO											I	I	I	U
12	OD1												I	A	O
13	OD2													E	O
14	NAV														A
15	SEA														

A = Absolutely Essential I = Important U = Unimportant
 E = Essential O = Ordinary X = Undesireable

Continue Print


Slika P2.2. Unos međusobnih kodova bliskosti dobivenih metodom anketiranja

Score Vector


	Code	Score
Absolutely Essential	A	45
Essential	E	11
Important	I	3
Ordinary Importance	O	1
Unimportant	U	0
Undesireable	X	-45

Slika P2.3. Definiranje težinskih faktora za pojedine kodove bliskosti


Izlazni rezultati:




Slika P2.4. Generirane najizglednije projektne alternative, tj. varijante od 1 do 4




Slika P2.5. Generirane najizglednije projektne alternative, tj. varijante od 5 do 8



Slika P2.6. Generirane najizglednije projektne alternative, tj. varijante od 9 do 12



Slika P2.7. Generirane najizglednije projektne alternative, tj. varijante od 13 do 16



Slika P2.8. Generirane najizglednije projektne alternative, tj. varijante od 17 do 20

Prilog 3.

AHP metoda: Tablični prikaz dobivenih lokalnih i ukupnih prioriteta pomoću razvijenog prilagođenog alata za hijerarhijsko modeliranje u *Microsoft Excel*-u

Tablica P3.1. Procjena omjera težina kriterija uspoređivanjem u parovima korištenjem Saaty-jeve skale s izračunom prioriteta *AHP* metodom.

PROCJENA OMJERA TEŽINA KRITERIJA (Saaty-jeva skala)	SLP OCJENA LAYOUTA	CIJENA INVESTICIJE	ZADRŽAVANJE POSTOJEĆIH OBJEKATA	IZVEDIVOST INVESTICIJE	ŠIRENJE IZVAN GRANICA BRODOGRAD.		SLP OCJENA LAYOUTA	CIJENA INVESTICIJE	ZADRŽAVANJE POSTOJEĆIH OBJEKATA	IZVEDIVOST INVESTICIJE	ŠIRENJE IZVAN GRANICA BRODOGRAD.	SUMA PO REDOVIMA	PRIORITETI
SLP OCJENA LAYOUTA	1	1/5	1/3	1/3	1/3	→	0,07	0,07	0,04	0,08	0,06	0,31	0,061
CIJENA INVESTICIJE	5	1	3	1	3	→	0,33	0,35	0,36	0,23	0,53	1,80	0,370
ZADRŽAVANJE POSTOJEĆIH OBJEKATA	3	1/3	1	1	1/3	→	0,20	0,12	0,12	0,23	0,06	0,73	0,138
IZVEDIVOST INVESTICIJE	3	1	1	1	1	→	0,20	0,35	0,12	0,23	0,18	1,08	0,212
ŠIRENJE IZVAN GRANICA BRODOGRAD.	3	1/3	3	1	1	→	0,20	0,12	0,36	0,23	0,18	1,08	0,218
SUMA PO STUPCIMA	15,00	2,87	8,33	4,33	5,67		SUMA:					1	

Tablica P3.2. Usporedba alternativa u parovima korištenjem Saaty-jeve skale prema kriteriju 1 s izračunom pripadajućih lokalnih prioriteta AHP metodom.

USPOREDBA U PAROVIMA PO KRITERIJU 1 SLP OCIJENA RASPOREDA POVRŠINA																				
	VARIJANTA 1	VARIJANTA 2	VARIJANTA 3	VARIJANTA 4	VARIJANTA 5	VARIJANTA 6	VARIJANTA 7	VARIJANTA 8	VARIJANTA 9	VARIJANTA 10	VARIJANTA 11	VARIJANTA 12	VARIJANTA 13	VARIJANTA 14	VARIJANTA 15	VARIJANTA 16	VARIJANTA 17	VARIJANTA 18	VARIJANTA 19	VARIJANTA 20
VARIJANTA 1	1	1/5	5	1	1/5	3	5	1/3	1	3	1	1/7	1/3	3	1/3	1	1	1/5	3	1/5
VARIJANTA 2	5	1	7	3	1	5	5	3	3	5	3	1/3	1	5	1	3	3	1	5	1
VARIJANTA 3	1/5	1	1	1/7	1/9	1/3	1/3	1/7	1/5	1/3	1/5	1/9	1/9	1/3	1/9	1/7	1/7	1/9	1/3	1/9
VARIJANTA 4	1	1/3	7	1	1/3	5	5	1	1	5	3	1/5	1	5	1	1	1	1/3	7	1/3
VARIJANTA 5	5	1	9	3	1	7	7	3	3	7	5	1	1	7	1	3	3	1	7	1
VARIJANTA 6	1/3	1/5	3	1/5	1/7	1	1	1/5	1/5	1	1/3	1/7	1/7	1	1/7	1/5	1/5	1/7	1	1/7
VARIJANTA 7	1/5	1/5	3	1/5	1/7	1	1	1/5	1/5	1	1/3	1/7	1/7	1	1/7	1/5	1/5	1/7	1	1/7
VARIJANTA 8	3	1/3	7	1	1/3	5	5	1	3	5	3	1/3	1	5	1	3	3	1	5	1
VARIJANTA 9	1	1/3	5	1	1/3	5	5	1/3	1	5	3	1/3	1	5	1	3	3	1	5	1
VARIJANTA 10	1/3	1/5	3	1/5	1/7	1	1	1/5	1/5	1	1/3	1/7	1/7	1	1/7	1/5	1/5	1/7	1	1/7
VARIJANTA 11	1	1/3	5	1/3	1/5	3	3	1/3	1/3	3	1	1/7	1/3	3	1/3	1	1	1/5	3	1/5
VARIJANTA 12	7	3	9	5	1	7	7	3	3	7	7	1	1	7	1	3	3	1	7	1
VARIJANTA 13	3	1	9	1	1	7	7	1	1	7	3	1	1	5	1	3	3	1	5	1
VARIJANTA 14	1/3	1/5	3	1/5	1/7	1	1	1/5	1/5	1	1/3	1/7	1/5	1	1/7	1/5	1/5	1/7	1	1/7
VARIJANTA 15	3	1	9	1	1	7	7	1	1	7	3	1	1	7	1	3	3	1	5	1
VARIJANTA 16	1	1/3	7	1	1/3	5	5	1/3	1/3	5	1	1/3	1/3	5	1/3	1	1	1/3	7	1/3
VARIJANTA 17	1	1/3	7	1	1/3	5	5	1/3	1/3	5	1	1/3	1/3	5	1/3	1	1	1	5	1
VARIJANTA 18	5	1	9	3	1	7	7	1	1	7	5	1	1	7	1	3	1	1	7	1
VARIJANTA 19	1/3	1/5	3	1/7	1/7	1	1	1/5	1/5	1	1/3	1/7	1/5	1	1/5	1/7	1/5	1/7	1	1/7
VARIJANTA 20	5	1	9	3	1	7	7	1	1	7	5	1	1	7	1	3	1	1	7	1

Tablica P3.3. Usporedba alternativa u parovima korištenjem Saaty-jeve skale prema kriteriju 2 s izračunom pripadajućih lokalnih prioriteta *AHP* metodom.

USPOREDBA U PAROVIMA PO KRITERIJU 2 CIJENA INVESTICIJE	VARIJANTA 1	VARIJANTA 2	VARIJANTA 3	VARIJANTA 4	VARIJANTA 5	VARIJANTA 6	VARIJANTA 7	VARIJANTA 8	VARIJANTA 9	VARIJANTA 10	VARIJANTA 11	VARIJANTA 12	VARIJANTA 13	VARIJANTA 14	VARIJANTA 15	VARIJANTA 16	VARIJANTA 17	VARIJANTA 18	VARIJANTA 19	VARIJANTA 20	LOKALNI PRIORITETI
VARIJANTA 1	1	1/3	1	2	2	2	1	3	3	1	2	7	2	3	2	2	1/5	1	7	3	0,0587
VARIJANTA 2	3	1	3	5	5	5	3	7	7	3	5	8	5	7	4	4	1/2	4	8	7	0,1418
VARIJANTA 3	1	1/3	1	3	3	3	1	5	3	1	3	7	3	4	3	3	1/5	3	7	5	0,0774
VARIJANTA 4	1/2	1/5	1/3	1	1	1	1/3	3	1	1/3	1	5	1	3	1	1	1/7	1	5	3	0,0341
VARIJANTA 5	1/2	1/5	1/3	1	1	1	1/3	3	1	1/3	1	5	1	3	1	1	1/7	1	5	3	0,0341
VARIJANTA 6	1/2	1/5	1/3	1	1	1	1/3	3	1	1/3	1	5	1	3	1	1	1/7	1	5	3	0,0341
VARIJANTA 7	1	1/3	1	3	3	3	1	3	3	1	2	7	2	3	2	2	1/5	1	7	3	0,0631
VARIJANTA 8	1/3	1/7	1/5	1/3	1/3	1/3	1/3	1	1/3	1/5	1/3	3	1/3	1	1/3	1/3	1/8	1/4	3	1	0,0156
VARIJANTA 9	1/3	1/7	1/3	1	1	1	1/3	3	1	1/3	1	5	1	3	1	1	1/7	1	5	3	0,0332
VARIJANTA 10	1	1/3	1	3	3	3	1	5	3	1	2	7	2	3	2	2	1/5	1	7	3	0,0647
VARIJANTA 11	1/2	1/5	1/3	1	1	1	1/2	3	1	1/2	1	5	1	3	1	1	1/7	1	5	3	0,0350
VARIJANTA 12	1/7	1/8	1/7	1/5	1/5	1/5	1/7	1/3	1/5	1/7	1/5	1	1/5	1/3	1/5	1/5	1/9	1/5	2	1/3	0,0090
VARIJANTA 13	1/2	1/5	1/3	1	1	1	1/2	3	1	1/2	1	5	1	3	1	1	1/7	1	5	3	0,0350
VARIJANTA 14	1/3	1/7	1/4	1/3	1/3	1/3	1/3	1	1/3	1/3	1/3	3	1/3	1	1/3	1/3	1/8	1/4	3	1	0,0161
VARIJANTA 15	1/2	1/4	1/3	1	1	1	1/2	3	1	1/2	1	5	1	3	1	1	1/7	1	5	3	0,0354
VARIJANTA 16	1/2	1/4	1/3	1	1	1	1/2	3	1	1/2	1	5	1	3	1	1	1/7	1	5	3	0,0354
VARIJANTA 17	5	2	5	7	7	7	5	8	7	5	7	9	7	8	7	7	1	7	9	7	0,2115
VARIJANTA 18	1	1/4	1/3	1	1	1	1	4	1	1	1	5	1	4	1	1	1/7	1	5	3	0,0412
VARIJANTA 19	1/7	1/8	1/7	1/5	1/5	1/5	1/7	1/3	1/5	1/7	1/5	1/2	1/5	1/3	1/5	1/5	1/9	1/5	1	1/3	0,0083
VARIJANTA 20	1/3	1/7	1/5	1/3	1/3	1/3	1/3	1	1/3	1/3	1/3	3	1/3	1	1/3	1/3	1/7	1/3	3	1	0,0164

Tablica P3.4. Usporedba alternativa u parovima korištenjem Saaty-jeve skale prema kriteriju 3 s izračunom pripadajućih lokalnih prioriteta *AHP* metodom.

USPOREDBA U PAROVIMA PO KRITERIJU 3 ZADRŽAVANJE POSTOJEĆIH OBJEKATA		VARIJANTA 1	VARIJANTA 2	VARIJANTA 3	VARIJANTA 4	VARIJANTA 5	VARIJANTA 6	VARIJANTA 7	VARIJANTA 8	VARIJANTA 9	VARIJANTA 10	VARIJANTA 11	VARIJANTA 12	VARIJANTA 13	VARIJANTA 14	VARIJANTA 15	VARIJANTA 16	VARIJANTA 17	VARIJANTA 18	VARIJANTA 19	VARIJANTA 20
VARIJANTA 1	1	1	1/7	1/3	1	1	1/3	1/5	1/6	1/4	1/4	1	1/4	1	1/3	1	1/3	1/8	1/3	1/3	1/3
VARIJANTA 2	7	1	1/4	1/6	1/7	1/5	1/3	1/2	1/2	1/4	1/4	1/7	1/4	1/7	1/5	1/7	1/4	1/2	1/5	1/5	1/5
VARIJANTA 3	3	4	1	3	4	2	1/2	1/3	1	1	1	3	1	3	1	3	1	1/5	1	2	2
VARIJANTA 4	1	6	1/3	1	1	1/3	1/5	1/6	1/4	1/4	1/4	1	1/4	1	1/3	1	1/3	1/8	1/3	1/3	1/3
VARIJANTA 5	1	7	1/4	1	1	1/3	1/5	1/6	1/4	1/4	1/4	1	1/4	1	1/3	1	1/3	1/8	1/3	1/3	1/3
VARIJANTA 6	3	5	1/2	3	3	1	1/3	1/5	1/2	1/2	1/2	3	1/2	3	1	3	1/2	1/6	1	1	1
VARIJANTA 7	5	3	2	5	5	3	1	1/2	2	2	2	5	2	5	3	5	2	1/4	3	3	3
VARIJANTA 8	6	2	3	6	6	5	2	1	3	3	3	5	3	5	4	5	3	1/3	4	3	3
VARIJANTA 9	4	4	1	4	4	2	1/2	1/3	1	1	1	3	1	3	1	3	1	1/5	1	2	2
VARIJANTA 10	4	4	1	4	4	2	1/2	1/3	1	1	1	3	1	3	1	3	1	1/5	1	2	2
VARIJANTA 11	1	1/7	1/3	1	1	1/3	1/5	1/6	1/4	1/4	1/4	1	1/4	1	1/3	1	1/3	1/8	1/3	1/3	1/3
VARIJANTA 12	4	4	1	4	4	2	1/2	1/3	1	1	1	3	1	3	1	3	1	1/5	1	2	2
VARIJANTA 13	1	1/7	1/3	1	1	1/3	1/5	1/6	1/4	1/4	1/4	1	1/4	1	1/3	1	1/3	1/8	1/3	1/3	1/3
VARIJANTA 14	3	5	1	3	3	1	1/3	1/4	1	1	1	3	1	3	1	3	1	1/6	1	1	1
VARIJANTA 15	1	1/7	1/3	1	1	1/3	1/5	1/6	1/4	1/4	1/4	1	1/4	1	1/3	1	1/3	1/8	1/3	1/3	1/3
VARIJANTA 16	4	4	1	4	4	2	1/2	1/3	1	1	1	3	1	3	1	3	1	1/5	1	2	2
VARIJANTA 17	8	2	5	8	8	6	4	3	5	5	5	8	5	8	6	8	5	1	6	6	6
VARIJANTA 18	3	5	1	3	3	1	1/3	1/4	1	1	1	3	1	3	1	3	1	1/6	1	1	1
VARIJANTA 19	3	5	1/2	3	3	1	1/3	1/5	1/2	1/2	1/2	3	1/2	3	1	3	1/2	1/6	1	1	1
VARIJANTA 20	3	5	1/2	3	3	1	1/3	1/5	1/2	1/2	1/2	3	1/2	3	1	3	1/2	1/6	1	1	1

LOKALNI PRIORITETI
0,0148
0,0211
0,0517
0,0192
0,0198
0,0387
0,0892
0,1180
0,0533
0,0533
0,0148
0,0533
0,0148
0,0451
0,0148
0,0533
0,2019
0,0451
0,0387
0,0387

Tablica P3.5. Usporedba alternativa u parovima korištenjem Saaty-jeve skale prema kriteriju 4 s izračunom pripadajućih lokalnih prioriteta *AHP* metodom.

USPOREDBA U PAROVIMA PO KRITERIJU 4 IZVEDIVOST INVESTICIJE	VARIJANTA 1	VARIJANTA 2	VARIJANTA 3	VARIJANTA 4	VARIJANTA 5	VARIJANTA 6	VARIJANTA 7	VARIJANTA 8	VARIJANTA 9	VARIJANTA 10	VARIJANTA 11	VARIJANTA 12	VARIJANTA 13	VARIJANTA 14	VARIJANTA 15	VARIJANTA 16	VARIJANTA 17	VARIJANTA 18	VARIJANTA 19	VARIJANTA 20
VARIJANTA 1	1	1/4	3	1	1/2	2	1/3	1/3	1	1	1/2	1/2	2	1	1	3	1/5	1/2	7	1/3
VARIJANTA 2	4	1	8	4	3	7	2	2	4	4	3	3	7	4	4	8	1/2	3	9	2
VARIJANTA 3	1/3	1/8	1	1/3	1/4	1/2	1/5	1/5	1/3	1/3	1/4	1/4	1/2	1/3	1/3	1	1/9	1/4	3	1/5
VARIJANTA 4	1	1/4	3	1	1/2	2	1/3	1/3	1	1	1/2	1/2	2	1	1	3	1/5	1/2	7	1/3
VARIJANTA 5	2	1/3	4	2	1	4	1/2	1/2	2	2	1	1	4	2	2	5	1/4	1	8	1/2
VARIJANTA 6	1/2	1/7	2	1/2	1/4	1	1/4	1/4	1/2	1/2	1/3	1/3	1	1/2	1/2	2	1/8	1/3	4	1/4
VARIJANTA 7	3	1/2	5	3	2	4	1	1	3	3	2	2	4	3	3	5	1/3	2	8	1
VARIJANTA 8	3	1/2	5	3	2	4	1	1	3	3	2	2	4	3	3	5	1/3	2	8	1
VARIJANTA 9	1	1/4	3	1	1/2	2	1/3	1/3	1	1	1/2	1/2	2	1	1	3	1/5	1/2	7	1/3
VARIJANTA 10	1	1/4	3	1	1/2	2	1/3	1/3	1	1	1/2	1/2	2	1	1	3	1/5	1/2	7	1/3
VARIJANTA 11	2	1/3	4	2	1	4	1/2	1/2	2	2	1	1	4	2	2	5	1/4	1	8	1/2
VARIJANTA 12	2	1/3	4	2	1	4	1/2	1/2	2	2	1	1	4	2	2	5	1/4	1	8	1/2
VARIJANTA 13	1/2	1/7	2	1/2	1/4	1	1/4	1/4	1/2	1/2	1/3	1/3	1	1/2	1/2	2	1/8	1/3	4	1/4
VARIJANTA 14	1	1/4	3	1	1/2	2	1/3	1/3	1	1	1/2	1/2	2	1	1	3	1/5	1/2	7	1/3
VARIJANTA 15	1	1/4	3	1	1/2	2	1/3	1/3	1	1	1/2	1/2	2	1	1	3	1/5	1/2	7	1/3
VARIJANTA 16	1/3	1/8	1	1/3	1/4	1/2	1/5	1/5	1/3	1/3	1/4	1/4	1/2	1/3	1/3	1	1/9	1/4	3	1/5
VARIJANTA 17	5	2	9	5	4	8	3	3	5	5	4	4	8	5	5	9	1	4	9	3
VARIJANTA 18	2	1/3	4	2	1	4	1/2	1/2	2	2	1	1	4	2	2	5	1/4	1	8	1/2
VARIJANTA 19	1/7	1/9	1/3	1/7	1/8	1/4	1/8	1/8	1/7	1/7	1/8	1/8	1/4	1/7	1/7	1/3	1/9	1/8	1	1/8
VARIJANTA 20	3	1/2	5	3	2	4	1	1	3	3	2	2	4	3	3	5	1/3	2	8	1

LOKALNI PRIORITETI
0,0310
0,1240
0,0128
0,0310
0,0533
0,0183
0,0799
0,0799
0,0310
0,0310
0,0533
0,0533
0,0183
0,0310
0,0310
0,0128
0,1678
0,0533
0,0069
0,0799

Tablica P3.6. Usporedba alternativa u parovima korištenjem Saaty-jeve skale prema kriteriju 5 s izračunom pripadajućih lokalnih prioriteta *AHP* metodom.

USPOREDBA U PAROVIMA PO KRITERIJU 5 ŠIRENJE IZVAN GRANICA BRODOGRAD.	VARIJANTA 1	VARIJANTA 2	VARIJANTA 3	VARIJANTA 4	VARIJANTA 5	VARIJANTA 6	VARIJANTA 7	VARIJANTA 8	VARIJANTA 9	VARIJANTA 10	VARIJANTA 11	VARIJANTA 12	VARIJANTA 13	VARIJANTA 14	VARIJANTA 15	VARIJANTA 16	VARIJANTA 17	VARIJANTA 18	VARIJANTA 19	VARIJANTA 20
VARIJANTA 1	1	1	1	1	9	1	1	9	9	1	1	9	1	1	1	1	1	1	1	9
VARIJANTA 2	1	1	1	1	9	1	1	9	9	1	1	9	1	1	1	1	1	1	1	9
VARIJANTA 3	1	1	1	1	9	1	1	9	9	1	1	9	1	1	1	1	1	1	1	9
VARIJANTA 4	1	1	1	1	9	1	1	9	9	1	1	9	1	1	1	1	1	1	1	9
VARIJANTA 5	1/9	1/9	1/9	1/9	1	1/9	1/9	1	1	1/9	1/9	1	1/9	1/9	1/9	1/9	1/9	1/9	1/9	1
VARIJANTA 6	1	1	1	1	9	1	1	9	9	1	1	9	1	1	1	1	1	1	1	9
VARIJANTA 7	1	1	1	1	9	1	1	9	9	1	1	9	1	1	1	1	1	1	1	9
VARIJANTA 8	1/9	1/9	1/9	1/9	1	1/9	1/9	1	1	1/9	1/9	1	1/9	1/9	1/9	1/9	1/9	1/9	1/9	1
VARIJANTA 9	1/9	1/9	1/9	1/9	1	1/9	1/9	1	1	1/9	1/9	1	1/9	1/9	1/9	1/9	1/9	1/9	1/9	1
VARIJANTA 10	1	1	1	1	9	1	1	9	9	1	1	9	1	1	1	1	1	1	1	9
VARIJANTA 11	1	1	1	1	9	1	1	9	9	1	1	9	1	1	1	1	1	1	1	9
VARIJANTA 12	1/9	1/9	1/9	1/9	1	1/9	1/9	1	1	1/9	1/9	1	1/9	1/9	1/9	1/9	1/9	1/9	1/9	1
VARIJANTA 13	1	1	1	1	9	1	1	9	9	1	1	9	1	1	1	1	1	1	1	9
VARIJANTA 14	1	1	1	1	9	1	1	9	9	1	1	9	1	1	1	1	1	1	1	9
VARIJANTA 15	1	1	1	1	9	1	1	9	9	1	1	9	1	1	1	1	1	1	1	9
VARIJANTA 16	1	1	1	1	9	1	1	9	9	1	1	9	1	1	1	1	1	1	1	9
VARIJANTA 17	1	1	1	1	9	1	1	9	9	1	1	9	1	1	1	1	1	1	1	9
VARIJANTA 18	1	1	1	1	9	1	1	9	9	1	1	9	1	1	1	1	1	1	1	9
VARIJANTA 19	1	1	1	1	9	1	1	9	9	1	1	9	1	1	1	1	1	1	1	9
VARIJANTA 20	1/9	1/9	1/9	1/9	1	1/9	1/9	1	1	1/9	1/9	1	1/9	1/9	1/9	1/9	1/9	1/9	1/9	1

LOKALNI
PRIORITETI

0,0643
0,0643
0,0643
0,0643
0,0071
0,0643
0,0643
0,0643
0,0071
0,0071
0,0643
0,0643
0,0643
0,0643
0,0643
0,0643
0,0643
0,0643
0,0643
0,0071

Tablica P3.7. Izračun ukupnih prioriteta na temelju prioriteta kriterija i lokalnih prioriteta AHP metodom

LOKALNI PRIORITETI ALTERNATIVA		KRITERIJI					UKUPNI PRIORITETI ALTERNATIVA
		SLP OCJENA LAYOUTA	CIJENA INVESTICIJE [k€]	ZADRŽAVANJE POSTOJEĆIH OBJEKATA, [%]	IZVEDIVOST INVESTICIJE [%]	ŠIRENJE IZVAN GRANICA BRODOGRAD.	
PRIORITETI KRITERIJA		0,061	0,370	0,138	0,212	0,218	
ALTERNATIVE	VARIJANTA 1	0,0299	0,0587	0,0148	0,0310	0,0643	0,046
	VARIJANTA 2	0,0850	0,1418	0,0211	0,1240	0,0643	0,102
	VARIJANTA 3	0,0103	0,0774	0,0517	0,0128	0,0643	0,053
	VARIJANTA 4	0,0489	0,0341	0,0192	0,0310	0,0643	0,038
	VARIJANTA 5	0,0978	0,0341	0,0198	0,0533	0,0071	0,034
	VARIJANTA 6	0,0117	0,0341	0,0387	0,0183	0,0643	0,036
	VARIJANTA 7	0,0115	0,0631	0,0892	0,0799	0,0643	0,068
	VARIJANTA 8	0,0675	0,0156	0,1180	0,0799	0,0071	0,044
	VARIJANTA 9	0,0577	0,0332	0,0533	0,0310	0,0071	0,031
	VARIJANTA 10	0,0117	0,0647	0,0533	0,0310	0,0643	0,053
	VARIJANTA 11	0,0264	0,0350	0,0148	0,0533	0,0643	0,042
	VARIJANTA 12	0,1136	0,0090	0,0533	0,0533	0,0071	0,033
	VARIJANTA 13	0,0768	0,0350	0,0148	0,0183	0,0643	0,038
	VARIJANTA 14	0,0119	0,0161	0,0451	0,0310	0,0643	0,033
	VARIJANTA 15	0,0780	0,0354	0,0148	0,0310	0,0643	0,041
	VARIJANTA 16	0,0385	0,0354	0,0533	0,0128	0,0643	0,039
	VARIJANTA 17	0,0429	0,2115	0,2019	0,1678	0,0643	0,160
	VARIJANTA 18	0,0840	0,0412	0,0451	0,0533	0,0643	0,051
	VARIJANTA 19	0,0120	0,0083	0,0387	0,0069	0,0643	0,025
	VARIJANTA 20	0,0840	0,0164	0,0387	0,0799	0,0071	0,035

Kratki životopis:

Tin Matulja rođen je 14. siječnja 1979. godine u Rijeci. Osnovnu školu pohađao je u Opatiji.

Godine 1997. završio je srednju Tehničku školu u Rijeci, s odličnim uspjehom, te stekao zvanje brodograđevni tehničar.

Iste 1997. godine upisuje se kao redovni student na sveučilišni studij brodogradnje na Tehničkom fakultetu u Rijeci. Tijekom studija više puta je nagrađivan od strane Fakultetskog vijeća kao najbolji student. Također je bio demonstrator za više kolegija.

Godine 2003. diplomirao je s odličnim uspjehom, te stekao visoku stručnu spremu i stručni naziv diplomirani inženjer brodogradnje.

Godine 2003. zapošljava se u poduzeću za gradnju malih plovnih objekata Flymar d.o.o. gdje je radio kao voditelj proizvodnje, te stekao iskustva i saznanja vezana za gradnju plovnih objekata.

1. rujna 2004. godine primljen je na mjesto znanstvenog novaka na Zavodu za brodogradnju i inženjerstvo morske tehnologije Tehničkog fakulteta Sveučilišta u Rijeci, u okviru znanstvenog projekta MZOŠ RH pod nazivom Tehnološko unapređenje metodologije gradnje trupa broda čiji je voditelj red. prof. dr. sc. N. Fafandjel, u znanstvenom polju Brodogradnja, znanstvene grane Tehnologija gradnje i održavanje plovnih objekata. Kao član tima na spomenutom projektu sudjelovao je na većem broju znanstveno istraživačkih projekata za privredu. Na Katedri za tehnologiju i organizaciju brodogradnje aktivno sudjeluje u nastavi održavanjem vježbi na nekoliko kolegija.

U studenom 2004. godine upisao je poslijediplomski znanstveni studij za stjecanje doktorata znanosti na Tehničkom fakultetu Sveučilišta u Rijeci, smjer Projektiranje i gradnja plovnih objekata.

U prosincu 2008. godine primljen je na mjesto asistenta na Zavodu za brodogradnju i inženjerstvo morske tehnologije Tehničkog fakulteta Sveučilišta u Rijeci.

Od najranije životne dobi do danas, više od 20 godina, bavi se jedrenjem, što je uvelike pridonijelo posebnom shvaćanju plovnih objekata i brodogradnje same.

Živi sa suprugom i troje djece u Lovranu.

Govori i piše engleski i talijanski jezik.
